

**UNIVERSIDAD MAYOR DE SAN ANDRÉS**  
**FACULTAD DE CIENCIAS PURAS Y NATURALES**  
**CARRERA DE INFORMÁTICA**  
**POSTGRADO EN INFORMÁTICA**



**TESIS MAGISTER SCIENTIARUM**  
**PROGRAMA DE MAESTRÍA EN GERENCIA ESTRATÉGICA DE**  
**TECNOLOGÍAS Y SISTEMAS DE INFORMACIÓN**  
**(GETSI) VERSIÓN 1 GESTIÓN 2006 - 2007**

**MODELO PREDICTIVO DE DEMANDA BASADO EN REDES**  
**NEURONALES PARA APROVISIONAMIENTO EN EMPRESAS**  
**TEXTILES**

**POR: Lic. Ruben Marcos Laura Huaita**  
**TUTOR: M. Sc. Elizabeth Patricia Pommier Gallo**

**La Paz – Bolivia**

**2020**

## **DEDICATORIA**

A Dios por su infinito amor compañía.

A mi hijo amado Lucas, impulso y estímulo de mi vida, para llevar adelante enormes retos y perseverar en ellos.

A mis padres Teodoro y Natalia, por su apoyo y afecto incondicional en las vicisitudes. A mi hermana Jhovana por su confianza y apoyo.

## **AGRADECIMIENTOS**

Expresar mi agradecimiento a mi Tutora de tesis, Lic. Elizabeth Pommier, quien, mediante su guía y apoyo coadyuvó en lograr este objetivo.

Sincero y firme agradecimiento a Paola, por su vital apoyo y fuerza para seguir adelante pese a las adversidades.

Agradecer a mi amigo Juan Carlos, por su constante ánimo y apoyo para culminar con éxito este gran propósito.

Agradecer a mis amigos y compañeros, cuyo impulso se tradujo en motivación para avanzar con decidido esfuerzo

## **RESUMEN**

En la actualidad, la planificación es una necesidad apremiante. Un objetivo importante de la planificación es tratar de prever lo que puede suceder en el futuro. El presente trabajo fue dirigido hacia a las empresas del sector textil y contó con su enorme respaldo.

La tarea consistió en coadyuvar en la planeación de una demanda precisa y adecuada, que permita a nivel operacional y estratégico un aprovisionamiento de suministros que minimice costos y mejore la utilidad de la empresa, permitiéndole mantenerse competitiva ante las fluctuaciones de mercado y cursos de acción de sus competidores.

En la actualidad la obtención de un pronóstico de demanda se realiza mediante técnicas basadas en métodos estadísticos, sin embargo, los datos obtenidos se muestran susceptibles a error, y por consiguiente en desmedro de las utilidades de las empresas.

Fundamentado en esta situación y a partir de un enfoque de cadena de suministros, se reconoce en las empresas del sector textil, la necesidad de realizar pronósticos más certeros a fin de reducir las faltas, pérdidas por escasa o excesiva producción; resultado alcanzable a través de herramientas que permitan establecer las relaciones lineales y no lineales que se establecen entre la demanda y las principales variables que influyen en esta. En tal contexto emergen las Redes Neuronales Artificiales (RNA), como una herramienta efectiva para dar solución a la problemática planteada.

Las RNA representan una de las técnicas más conocidas de las que forman parte, la Inteligencia Artificial y que se inspira en la naturaleza de la inteligencia humana y su afán por comprender y desarrollar entidades inteligentes simples, para crear sistemas de inteligencia complejos.

# ÍNDICE

<b>CAPÍTULO I.....</b>	<b>1</b>
<b>ASPECTOS GENERALES.....</b>	<b>1</b>
1.1. ANTECEDENTES .....	1
1.2. PLANTEAMIENTO DEL PROBLEMA.....	2
1.3. OBJETIVO GENERAL .....	3
1.3.1. OBJETIVOS ESPECÍFICOS .....	3
1.4. HIPÓTESIS.....	3
1.5. RESULTADOS DE LA INVESTIGACIÓN .....	3
1.6. OPERACIONALIZACIÓN DE VARIABLES.....	5
<b>CAPÍTULO II .....</b>	<b>7</b>
<b>MARCO TEÓRICO .....</b>	<b>7</b>
2.1. MARCO CONCEPTUAL.....	7
2.1.1. APROVISIONAMIENTO EN EMPRESAS TEXTILES .....	7
2.1.2. PRONÓSTICO .....	8
2.1.3. DEMANDA .....	8
2.1.4. PRONÓSTICO DE LA DEMANDA.....	9
2.1.5. ENFOQUES DE PRONÓSTICO.....	9
2.1.6. EL PROCESO DEL PRONÓSTICO.....	10
2.1.7. CLASIFICACIÓN DE PRONÓSTICO.....	10
2.1.8. SEGÚN EL HORIZONTE DEFINIDO .....	10
2.1.9. TIPO DE PRONÓSTICO.....	11
2.2. MARCO REFERENCIAL .....	11
2.2.1. MÉTODOS DE PRONÓSTICO .....	11
2.2.2. REDES NEURONALES ARTIFICIALES.....	12
2.2.3. FUNCIÓN DE ACTIVACIÓN.....	14
2.2.4. FUNCIÓN DE SALIDA .....	16
2.2.5. ETAPAS PARA LA CREACIÓN DE UNA RNA.....	17

2.2.6. <i>ELECCIÓN DEL CONJUNTO DE ENTRENAMIENTO</i> .....	18
2.2.8. <i>PARÁMETROS DE APRENDIZAJE</i> .....	19
2.2.9. <i>CLASIFICACIÓN DE LAS RNA</i> .....	20
2.2.10. <i>PERCEPTRÓN MULTICAPA</i> .....	22
<b>CAPÍTULO III</b> .....	<b>27</b>
<b>METODOLOGÍA DE LA INVESTIGACIÓN</b> .....	<b>27</b>
3.1. MÉTODOS DE INVESTIGACIÓN .....	27
3.2. TIPO DE INVESTIGACIÓN.....	27
3.3. UNIVERSO O POBLACIÓN DE ESTUDIO .....	28
3.3.1. <i>DETERMINACIÓN Y ELECCIÓN DE LA MUESTRA</i> .....	30
3.4. SUJETOS VINCULADOS A LA INVESTIGACIÓN .....	34
3.5. FUENTES Y DISEÑO DE LOS INSTRUMENTOS DE RELEVAMIENTO DE LA INFORMACIÓN .....	36
3.5.1. <i>FUENTES DE LA INVESTIGACIÓN</i> .....	36
3.5.2. <i>DISEÑO DE LOS INSTRUMENTOS DE RELEVAMIENTO DE LA INFORMACIÓN</i> .....	37
3.5.2.1. <i>ENCUESTAS RESPECTO A LOS PRODUCTO</i> .....	38
3.5.2.2. <i>ENCUESTAS RESPECTO AL PRECIO</i> .....	39
3.6. PROCESAMIENTO Y ANALISIS DE LA INFORMACIÓN .....	40
3.6.1. <i>CREACIÓN DEL MODELO PREDICTIVO</i> .....	40
<b>CAPÍTULO IV</b> .....	<b>46</b>
<b>MARCO PRÁCTICO</b> .....	<b>46</b>
4.1. CONSTRUCCIÓN DE LA RED NEURONAL BASE.....	46
4.2. DESCRIPCIÓN DE LOS PRODUCTOS .....	46
4.3. DEFINICIÓN DE LAS VARIABLES DE ENTRADA .....	47
4.4. DEFINICIÓN DE LAS VARIABLES DE SALIDA.....	48
4.5. TOPOLOGÍA DE LA RED.....	48
4.6. HERRAMIENTA DE APLICACIÓN .....	50
4.7. CONFIGURACIÓN.....	50

4.7.1. <i>REQUERIMIENTOS DE HARDWARE Y SOFTWARE</i> .....	50
4.8. INSTANCIAS DE PRUEBAS .....	51
4.9. INSTANCIAS DE PRUEBAS PARA EL ENTRENAMIENTO .....	53
4.10. INSTANCIAS DE PRUEBA PARA LA VALIDACIÓN .....	54
4.11. NORMALIZACIÓN DE DATOS.....	55
4.12. FASE DE ENTRENAMIENTO .....	58
4.13. PROCESO DE ENTRENAMIENTO DE LA RNA .....	58
4.13.1. <i>CONFIGURACIONES PRIMER PRODUCTO DE LAS TOPOLOGÍAS</i> .....	58
4.13.2. <i>CONFIGURACIÓN 1</i> .....	59
4.15. RESUMEN DEL PROCESO DE ENTRENAMIENTO DE LA RNA DEL PRIMER PRODUCTO (ALGODÓN).....	64
4.16. CONFIGURACIÓN ESCOGIDA PARA EL PRIMER PRODUCTO (ALGODÓN) .....	65
4.17. PROCESO DE ENTRENAMIENTO DE LA RNA DEL SEGUNDO PRODUCTO (HILANDERÍA) .....	66
4.18. PROCESO DE ENTRENAMIENTO DE LA RNA DEL PRODUCTO TRES (TEJIDO PLANO).....	67
4.19. FASE DE VALIDACIÓN .....	68
4.19.1. <i>VALIDACIÓN DE LAS REDES DEL PRIMER PRODUCTO (ALGODÓN)</i> .....	68
4.20. PROCEDIMIENTO EN TENSORFLOW .....	68
4.21. TASA DE ERROR .....	69
4.22. VALIDACIÓN DE LAS REDES DEL PRODUCTO HILANDERÍA .....	70
4.23. VALIDACIÓN PRODUCTO TEJIDO PLANO .....	70
4.24. APLICACIÓN DE PRONÓSTICO .....	71
4.25. CONEXIÓN JAVASCRIPT – TENSORFLOW .....	71
4.26. RENDIMIENTO DE LAS RNA FRENTE A MÉTODOS ESTADÍSTICOS.....	72
<b>CAPÍTULO V.....</b>	<b>75</b>
<b>CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>75</b>
5.1. CONCLUSIONES .....	75
5.2. RECOMENDACIONES .....	75
<b>REFERENCIA BIBLIOGRÁFICA .....</b>	<b>76</b>

<b>ANEXO 1: POLÍTICAS INHERENTES AL SECTOR TEXTIL .....</b>	<b>79</b>
<b>ANEXO 2: HERRAMIENTA TENSORFLOW .....</b>	<b>83</b>
<b>ANEXO 3: DATOS HISTÓRICOS DE LOS PRODUCTOS HILANDERÍA Y TEJIDO PLANO.....</b>	<b>90</b>
<b>ANEXO 4: ENTRENAMIENTO Y VALIDACIÓN DE LA RNA.....</b>	<b>100</b>
<b>ANEXO 5: SELECCIÓN DE LAS VARIABLES DE ENTRADA .....</b>	<b>103</b>



## INDICE DE TABLAS

Tabla 1: Operacionalización de variables – Variable independiente.....	5
Tabla 2: Operacionalización de variables – Variable interviniente .....	6
Tabla 3: Operacionalización de variables – Variable dependiente.....	6
Tabla 4: Enfoques de pronóstico de demanda .....	9
Tabla 5: Empresas del sector textil .....	29
Tabla 6: Tipos de producción textil .....	32
Tabla 7: Entrevista pronóstico de demanda .....	37
Tabla 8: Entrevista a personal de producción. ....	38
Tabla 9: Entrevista a personal de planificación. ....	39
Tabla 10: Definición de variables de entrada del modelo.....	47
Tabla 11: Datos totales para el entrenamiento y validación .....	52
Tabla 12: Datos para la fase de entrenamiento .....	53
Tabla 13: Datos normalizados para la fase de entrenamiento.....	57
Tabla 14: Datos normalizados para la fase de validación.....	58
Tabla 15: Resumen del proceso de entrenamiento de la RN - Algodón.....	65
Tabla 16: Resumen del proceso de entrenamiento de la RNA - Hilandería .....	66
Tabla 17: Resumen del proceso de entrenamiento de la RNA - Tejido Plano .....	67
Tabla 18: Resumen del proceso de validación – Producto Algodón .....	69
Tabla 19: Resumen del proceso de validación – Producto Hilandería. ....	70
Tabla 20: Resumen del proceso de validación – Producto Tejido Plano.....	71
Tabla 21: Cuadro comparativo del producto Algodón .....	74

## INDICE DE FIGURAS

Figura 1: Ejemplo de una red neuronal totalmente conectada.....	13
Figura 2: Función de activación (función lineal).....	14
Figura 3: Función de activación (sigmoideal).....	15
Figura 4: Función de activación (tangente hiperbólica).....	15
Figura 5: Representación de una red neuronal artificial.....	16
Figura 6: Taxonomía de las redes neuronales según ciertos parámetros.....	21
Figura 7: Red Perceptrón Multicapa. Conexionado feed-forward.....	23
Figura 8: Jerarquía de los kits de herramientas de TensorFlow.....	24
Figura 9: Producción de manufactura.....	25
Figura 10: Participación del sector textil en el PIB.....	26
Figura 11: Número de empresa manufactureras.....	28
Figura 12: Clúster de textiles.....	30
Figura 13: Clúster de textiles.....	31
Figura 14: Tipo de productos para la muestra.....	31
Figura 15: Sujetos vinculados a la investigación.....	35
Figura 16: Tipos de entrevistas realizadas a personal de planificación.....	36
Figura 17: Datos obtenidos por la Empresa Textil.....	42
Figura 18: Datos de ventas Empresa Textil.....	43
Figura 19: Datos de ventas y pronóstico – AMETEX.....	44
Figura 20: Resultado de demanda de productos.....	45
Figura 21: Productos textiles.....	46
Figura 22: Esquema del diseño de la red neuronal.....	49
Figura 23: Arquitectura de la red neuronal para cada producto.....	50
Figura 24: Datos para la fase de validación.....	55
Figura 25: Configuración de la red PRONOSTICADOR_1.....	59
Figura 26: Esquema de la red neuronal PRONOSTICADOR_1.....	60
Figura 27: Configuración de los parámetros solicitados por la red.....	60
Figura 28: Configuración de los pesos de la red PRONOSTICADOR_1.....	61
Figura 29: Imagen del entrenamiento realizado por la red PRONOSTICADOR_1.....	61

Figura 30: Configuración de la red PRONOSTICADOR_2.....	62
Figura 31: Esquema de la red neuronal PRONOSTICADOR_2 .....	63
Figura 32: Configuración de los parámetros solicitados por la red .....	63
Figura 33: Configuración de los pesos de la red PRONOSTICADOR_2 .....	63
Figura 34: Imagen del entrenamiento realizado por la red PRONOSTICADOR_2.....	64
Figura 35: Simulación con los datos de validación para la red PRONOSTICADOR_8 .....	68
Figura 36: Errores de la validación PRONOSTICADOR_8 .....	69

## INTRODUCCIÓN

El sector textil dentro de las empresas nacionales, ha experimentado cierto desarrollo al generar nuevas oportunidades de empleo y favorecer el crecimiento de la economía a través de su participación en el PIB, como lo mencionan datos proporcionados por el Instituto Nacional de Estadísticas – INE (INE 2016).

Según datos del Ministerio de Economía y Finanzas Públicas, experimento un crecimiento de 4.3%, asimismo representan el 9% el total de las empresas nacionales, contribuyendo con un 1% al PIB.

Sin embargo el sector se ha visto afectado por aspectos puntuales que influyen negativamente para un mayor crecimiento: falta de políticas orientadas a promocionar la producción nacional, y la ausencia de innovación tecnológica para mejorar los proceso productivos inherentes, la escasa inversión en innovación tecnológica respecto a otros países de la región, enunciado en el informe presentado por el Banco Mundial (2014), donde señala que el país destina apenas 0.3% de inversión en investigación y desarrollo, cuando el nivel mundial corresponde al 2.1%.

En la actualidad, la supervivencia de las empresas que pretendan ser competitivas, requieren de una perspectiva precisa de la demanda para poner en marcha los planes de aprovisionamiento, producción, y distribución, en este contexto, pronosticar por arriba de la demanda tiene entre sus consecuencias el excesivo aprovisionamiento de materias primas, originando obsolescencia o caducidad, y por otro lado, pronosticar por debajo de la demanda tiene como consecuencia la pérdida de las ventas y un posible incremento en los costos. El impulso que pretende otorgar este trabajo, es la posibilidad de desarrollar soluciones computacionales, las cuales coadyuven al desarrollo de un modelo predictivo de demanda que usa las técnicas de redes neuronales artificiales a fin optimizar el proceso de aprovisionamiento, y de ese modo gestionar un suministro eficiente de materias primas, con la consiguiente reducción de costos y volúmenes de almacenaje innecesarios.

Asimismo, propone el uso de una red neuronal artificial del tipo Perceptrón Multicapa para elaborar un modelo predictivo de la demanda de productos textiles, la cual realizará su fase de aprendizaje utilizando el Algoritmo Backpropagation que brinda una tasa de error mínima, su implementación se desarrollará bajo la tecnología de TensorFlow para la construcción de la red neuronal y del lenguaje JavaScript para el diseño de la interfaz gráfica de usuario, posibilitando conocer con la mayor exactitud la demanda y favorecer el aprovisionamiento de suministros de materiales requeridos para su fabricación y posterior venta.

# **CAPÍTULO I**

## **ASPECTOS GENERALES**

### **1.1. ANTECEDENTES**

La planeación en toda empresa es una necesidad, un punto vital. Se puede decir que el objetivo más importante de la planeación es tratar de prever lo que sucederá en el futuro a base de una recopilación de hechos o sucesos acaecidos con anterioridad. Los métodos estadísticos convencionales usan en general determinados parámetros o datos asociados a períodos de tiempo cuya relación con la previsión de demanda es complicada; la realidad es que muchos de los que toman decisiones en el campo predictivo de demanda lo hacen basándose en su instinto y experiencia originando un conocimiento de la demanda inexacta en detrimento de la empresa. A objeto de prever posibles inconvenientes, se realizaron numerosas investigaciones relacionadas a la predicción de la demanda mediante el uso de RNA en diferentes ámbitos, entre ellos se enumeran algunas investigaciones:

- Modelo de red neuronal digital para predicción climática.
- Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro.
- Pronóstico de ventas usando Redes Neuronales.

El uso de redes neuronales artificiales – RNA, establece una metodología frecuentemente usada para la resolución de predicciones debido a sus óptimos resultados, por otra parte, en cuanto a la logística de aprovisionamiento o suministro, se implementaron una serie de herramientas basadas en Tecnologías de Información – TI, entre ellas:

- a) Transferencia de información entre empresas utilizando mensajes electrónicos con contenidos estandarizados, con el fin de mejorar el aprovisionamiento.
- b) El abastecimiento electrónico o e-Procurement, recurrió a la autorización de compras, sin embargo, enfrenta elevados costes de operacionalización al requerir procesos con estándares de calidad.

- c) La administración, estimación y análisis de la demanda futura o “Forecasting”, es fundamental para la toma estratégica, operativa y táctica de decisiones, ya que por medio de pronósticos cuantitativos pueden representarse la base de los planes a largo plazo de una organización.

El presente trabajo establece una relación directa e indivisible entre la demanda y la logística de aprovisionamiento, utilizando inicialmente un modelo predictivo construido a partir de una red neuronal, la cual procura establecer la demanda precisa de un producto textil con la menor tasa de error posible, los resultados emitidos por la RNA, permitirán formular una eficiente planificación de suministro de materias primas en la etapa de aprovisionamiento.

## **1.2. PLANTEAMIENTO DEL PROBLEMA**

El pronóstico de la demanda es una actividad esencial para la formulación de planes de suministros, de producción y de ventas, sin embargo, la misma aún no tiene un nivel de priorización alta, por lo que no se cuenta con información precisa, que permita una adecuada toma de decisiones por parte de los altos mandos gerenciales.

En la actualidad las empresas en estudio, utilizan análisis estadístico de ventas para tener alguna certeza de la demanda a ser requerida en la próxima gestión, sin embargo dichos análisis suelen ser inexactos, al ser planteados por la experiencia, sin considerar factores externos o utilizando métodos estadísticos convencionales, que por lo general se basan en determinados parámetros o datos asociados a períodos de tiempo cuya relación con la previsión de demanda es compleja, la realidad es que muchos de los que toman decisiones en el campo de la previsión de demanda lo hacen basándose en su instinto y experiencia y no apoyadas en modelos de predicción avanzados.

Las dificultades descritas, repercuten directamente en una mala planificación de aprovisionamiento de materias primas, repercutiendo en erogación de costos adicionales por compras excesivas y los consiguientes costos de almacenamiento, o por pérdida de ventas ante la carencia de suministros.

### **1.3. OBJETIVO GENERAL**

Desarrollar un modelo predictivo de demanda basado en una red neuronal artificial para mejorar la logística de aprovisionamiento en empresas del sector textil.

#### **1.3.1. OBJETIVOS ESPECÍFICOS**

Entre los objetivos específicos se encuentran:

- Desarrollar y entrenar una red neuronal artificial a partir de las principales variables que influyen en la demanda, con un desempeño que permita su utilización en el proceso de provisión de aprovisionamiento en empresas textiles.
- Establecer la posibilidad de uso de RNA como técnica confiable para pronóstico y su implementación en empresa textiles nacionales.
- Evaluar los resultados emitidos por la RNA y comprobar si benefician a un aprovisionamiento textil adecuado.

### **1.4. HIPÓTESIS**

Un modelo predictivo de demanda basado en redes neuronales, asiste a una adecuada logística de aprovisionamiento en empresas del sector textil.

### **1.5. RESULTADOS DE LA INVESTIGACIÓN**

El presente trabajo, mostró la significativa importancia que tiene para las organizaciones dedicadas al sector textil, la correcta previsión de la demanda, pues ella se convierte en una herramienta sustancial para llevar a cabo una adecuada planificación empresarial del aprovisionamiento de suministros requeridos.

La mayoría de empresas guían sus acciones mediante el uso de modelos estadísticos para efectuar sus pronósticos, sin embargo, se verificó que la evolución de modelos más complejos basados en el uso de Redes Neuronales Artificiales, colaboran de sobremanera a la obtención de resultados



más efectivos en términos de una predicción apropiada de la demanda y por consiguiente en optimizar procesos de producción e inventarios, generando mayores utilidades económicas para las empresas.

## 1.6. OPERACIONALIZACIÓN DE VARIABLES

Tabla 1: *Operacionalización de variables – Variable independiente.*

Variable independiente				
VARIABLE	TIPO DE VARIABLE	OPERACIONALIZACIÓN	DIMENSIÓN	DEFINICIÓN
Pronóstico de demanda basado en redes neuronales.	Variable independiente: Pronóstico basado en redes neuronales	Pronóstico basado en redes neuronales: Es un modelo computacional, basado en un conjunto de neuronas (artificiales), las cuales buscan una analogía al comportamiento humano, prediciendo mediante datos históricos.	Pronóstico basado en redes neuronales: Red neuronal multicapa (perceptrón multicapa). Aprendizaje supervisado en Redes neuronales. Método de predicción cuantitativo.	<ol style="list-style-type: none"> <li>Este es uno de los tipos de redes más comunes. Se basa en otra red más simple llamada perceptrón simple solo que el número de capas ocultas puede ser mayor o igual que una.</li> <li>Se entrena al algoritmo otorgándole las preguntas, denominadas características, y las respuestas, denominadas etiquetas. Esto se hace con la finalidad de que el algoritmo las combine y pueda hacer predicciones.</li> <li>Esta metodología se utiliza para analizar los patrones de demanda como: tendencia, estacionalidad, ciclos llegar a hacer pronósticos para el futuro, es decir, se basa sustancialmente en datos históricos.</li> </ol>
INDICADOR	NIVEL DE MEDICIÓN	UNIDAD DE MEDIDA	ÍNDICE	VALOR
Porcentaje de aprendizaje	De razón	%	Índice de aprendizaje	Obtener el margen de error del modelo de pronóstico, según el porcentaje de aprendizaje.

Tabla 2: Operacionalización de variables – Variable interviniente

<b>Variable interviniente</b>				
<b>VARIABLE</b>	<b>TIPO DE VARIABLE</b>	<b>OPERACIONALIZACIÓN</b>	<b>DIMENSIÓN</b>	<b>DEFINICIÓN</b>
Empresas sector textil	Variable interviniente: Empresas sector textil.			

Tabla 3: Operacionalización de variables – Variable dependiente.

<b>Variable dependiente</b>				
<b>VARIABLE</b>	<b>TIPO DE VARIABLE</b>	<b>OPERACIONALIZACIÓN</b>	<b>DIMENSIÓN</b>	<b>DEFINICIÓN</b>
Logística de aprovisionamiento	Variable dependiente: Logística de aprovisionamiento	Optimizar logística de aprovisionamiento: La optimización busca adaptar acciones y procedimientos para que realicen sus tareas de la forma más eficiente posible, en el caso de esta investigación, posibilitar que la logística de aprovisionamiento se realice de la manera más efectiva.	Optimizar logística de aprovisionamiento: Cuantificación de la demanda. Gestión de compras	Conocimiento de la demanda de productos según datos históricos. Compras según las necesidades: Se compra sólo lo que se necesite en el momento, siempre y cuando no exista incertidumbre en el mercado.
<b>INDICADOR</b>	<b>NIVEL DE MEDICIÓN</b>	<b>UNIDAD DE MEDIDA</b>	<b>ÍNDICE</b>	<b>VALOR</b>
Porcentaje de optimización	De razón	%	Índice de optimización	La optimización de la logística de aprovisionamiento permitirá reducir tiempos y costos.

## **CAPÍTULO II**

### **MARCO TEÓRICO**

El presente capítulo, desarrolla las bases teóricas relacionadas a la investigación presentada en el planteamiento del problema.

#### **2.1. MARCO CONCEPTUAL**

##### **2.1.1. APROVISIONAMIENTO EN EMPRESAS TEXTILES**

El abastecimiento o aprovisionamiento es la función logística mediante la cual se provee a una empresa de todo el material necesario para su funcionamiento, supervisión desde el proceso en que se obtienen las materias primas, la fabricación de los productos, producción, distribución, transporte y entrega de estos.

Para que el proceso se lleve a cabo con la normalidad y eficacia necesaria debe contar con los componentes fundamentales, tales como:

- *Proveedores*: aquellas personas u organizaciones que se encargan de distribuir, ofrecer, conceder o arrendar el uso de bienes y servicios.
- *Transporte*: encargados del traslado de materias primas, productos terminados e insumos entre empresas y clientes.
- *Fabricantes*: corresponde a los que transforman la materia prima en algún artículo.
- *Clientes*: parte importante de la cadena de suministros, aquellos cuyas necesidades deben estar cubiertas.
- *Comunicación*: es una característica básica para que las operaciones entre cada elemento de la cadena fluyan y se desarrolle correctamente.
- *Tecnología*: permite a los elementos de la cadena de abastecimiento optimizar sus tareas y realizarlas en menor tiempo.

### **2.1.2. PRONÓSTICO**

Es un proceso que consiste en utilizar datos históricos para determinar acontecimientos futuros, consiste en reducir el rango de incertidumbre dentro del cual se toman las decisiones que afectan el futuro del negocio y con él a todas las partes involucradas.

### **2.1.3. DEMANDA**

Su observación, constituye el elemento principal del presente trabajo, y se refiere a las cantidades de un producto que los consumidores están dispuestos a comprar a los posibles precios del mercado.

La administración de la demanda implica reconocer fuentes de demanda para los bienes y servicios de una empresa, predecir la demanda y determinar la manera como la empresa satisfará esa demanda. Las predicciones de demanda pronostican la cantidad y la duración de los bienes y servicio de una empresa.

### **2.1.3. ELEMENTOS DE LA DEMANDA**

Se considera que la demanda se encuentra influenciada por cinco supuestos que determinarán el aumento o la disminución de la misma:

- *Precio.* El precio de los bienes y los servicios, es decir, el valor monetario los mismos, generalmente los precios son inversamente proporcionales a la demanda.
- *Oferta.* El segundo supuesto es la disposición de los bienes y servicios (oferta), es decir si existe algún individuo o empresa los ofrece y en qué cantidades lo realiza.
- *Lugar.* Puede ser mencionado el lugar, es decir cuál es el medio en el que se ofrece a los bienes o servicios, este espacio puede ser físico o virtual.
- *Capacidad de pago.* Se encuentra la capacidad de pago del demandante, es decir si posee los medios monetarios para acceder a los bienes.
- *Necesidades.* El último supuesto que puede ser mencionado son los deseos y las necesidades.

#### 2.1.4. PRONÓSTICO DE LA DEMANDA

El pronóstico de la demanda consiste en hacer una estimación de nuestras futuras ventas (ya sea en unidades físicas o monetarias) de uno o varios productos (generalmente todos), para un periodo de tiempo determinado (generalmente un mes). El realizar el pronóstico de la demanda nos permitirá elaborar nuestra proyección o presupuesto de ventas (demanda en unidades físicas multiplicado por el precio del producto) y, a partir de ésta, poder elaborar las demás proyecciones o presupuestos.

#### 2.1.5. ENFOQUES DE PRONÓSTICO

Según [Thompson98] los enfoques de cómo resolver problemas de pronósticos son los siguientes:

- *Pronósticos cuantitativos.* Este tipo maneja una variedad de modelos matemáticos que utilizan datos históricos y/o variables causales para pronosticar la demanda, como los mostrados en la Tabla 4.
- *Pronósticos cualitativos.* Este tipo incorpora factores importantes tales como la intuición, emociones, experiencias personales del que toma la decisión, y un sistema de valores para alcanzar un pronóstico.

Tabla 4: Enfoques de pronóstico de demanda

Enfoque	Tipo de modelo	Descripción
Cualitativo	<b>Modelos cualitativos</b> Datos históricos, Técnica de grupo, Nominal, etc.	Preguntas hechas a un grupo de expertos para recabar opiniones. Hace analogías con el pasado de una manera razonada. Proceso de grupo que permite la participación con votación forzada.
	<b>Modelos cuantitativos</b> Series de tiempo, Medida o promedio Móvil simple, etc.	Promedia históricos para predecir el futuro basándose en ese promedio.
Cuantitativo	<b>Modelo de suavizado exponencial</b>	Da pesos relativos a los pronósticos anteriores y a la demanda más reciente.
	<b>Modelos cuantitativos causales</b>	Describe una relación funcional entre las variables y cantidad pronosticada.

Fuente: Krajewski, Lee J.

### **2.1.6. EL PROCESO DEL PRONÓSTICO**

Los pronósticos se elaboran siguiendo los pasos que se indican a continuación:

1. Formulación del problema y recolección de datos.
2. Manipulación y limpieza de datos.
3. Construcción y evaluación del modelo.
4. Aplicación del modelo (el pronóstico real).
5. Evaluación del pronóstico.

### **2.1.7. CLASIFICACIÓN DE PRONÓSTICO**

Se consideran dos tipos de clasificación de pronóstico: según el horizonte definido y según el tipo de pronóstico. A continuación, se detalla cada uno de estos tipos:

### **2.1.8. SEGÚN EL HORIZONTE DEFINIDO**

Según el horizonte de tiempo definido según [2] Tawfik, L. & Chauvel, A.M., se tiene:

*Pronóstico a corto plazo.* Este tipo de pronóstico tiene un lapso de hasta un año, pero es generalmente menor a tres meses.

*Pronóstico a mediano plazo.* Es un pronóstico de rango mediano o intermedio, generalmente con un lapso de tres meses a tres años.

*Pronóstico a largo plazo.* Generalmente con lapsos de tres años o más.

El problema a resolver se ubica dentro del pronóstico de la demanda a corto y mediano plazo, ya que el horizonte de predicción abarca la estimación de la demanda de un producto desde un determinado mes hasta un año; por otro lado, se desea conocer la demanda continua de un producto o de toda una línea de productos para un segmento en particular, por lo cual está orientado a una fracción de población determinada.

### **2.1.9. TIPO DE PRONÓSTICO**

- a) Pronósticos subjetivos: Son aquellos en la que las personas de experiencia en ventas, mercadotecnia, gerentes expresan cuál es su parecer respecto a las ventas que se puede esperar para el futuro.
- b) Pronósticos basados en un índice: Dependen de un índice de base para su precisión además del grado de correlación entre la demanda real y el pronóstico basado en el índice.
- c) Pronósticos basados en promedios: Este pronóstico se basa en el promedio de los datos de ventas, quiere decir que la demanda anterior representa la demanda futura. Con una buena aplicación de los métodos de este tipo de pronósticos y ciertos ajustes, el promedio de los datos de la demanda puede dar un valor aproximado muy bueno.
- d) Pronósticos estadísticos: El pronóstico basado en el análisis estadístico de la demanda es el procedimiento más exacto siempre que exista una relación entre el pasado y el futuro. En realidad, el pasado brinda la mejor base para las decisiones referentes a la acción futura.
- e) Métodos combinados: Es posible y quizá sea deseable combinar algunos o todos los tipos de pronósticos mencionados y hasta añadirle otros métodos.

## **2.2. MARCO REFERENCIAL**

### **2.2.1. MÉTODOS DE PRONÓSTICO**

La clasificación de los métodos de pronóstico se basa en dos grandes enfoques: el enfoque cuantitativo y el cualitativo. A continuación, se menciona el método cuantitativo perteneciente a dicho enfoque.

#### **2.2.1.1. MÉTODOS CUANTITATIVOS**

Este tipo de métodos se emplean cuando la situación es estable y existen datos históricos. Así mismo requieren técnicas estadísticas o herramientas matemáticas. Entre algunas de ellas tenemos [Jaramillo+05]:



- Análisis de series de tiempo
- Promedio de movimiento simple
- Promedio de movimiento ponderado
- Ajuste exponencial
- Análisis de regresión lineal
- Método Winters
- Modelos de simulación

Los métodos verificados y con mayor utilización en las empresas son Análisis de Series de Tiempo y ajustes exponenciales. Fuente [datos obtenidos por entrevistas]

## **2.2.2. REDES NEURONALES ARTIFICIALES**

Una Red Neuronal es un sistema de procesamiento de información que intenta reproducir de cierta manera las capacidades que posee el cerebro humano a través de sus neuronas para reconocer patrones, predecir y tomar decisiones frente a sucesos dados de la experiencia pasada, representados por la información histórica de diversas variables de información.

### **2.2.2.1. ESTRUCTURA BÁSICA DE UNA RNA**

La estructura de las Redes Neuronales Artificiales consiste en la organización y disposición de las neuronas dentro de la red neuronal. De esta manera, las “neuronas” se estructuran formando capas, es decir, se agrupan en conjuntos o grupos de neuronas, las que conforman las llamadas Redes Neuronales.

Adicionalmente, las neuronas pueden formar “Slabs”, los cuales son un subconjunto de neuronas dentro de una determinada capa de la red neuronal, las que poseen un número de características similares, como, por ejemplo, poseer una misma función de activación.

La estructura clásica de una Red Neuronal (ver Figura 1) se compone de una capa de entrada, una capa oculta y una capa de salida.




Figura 1: Ejemplo de una red neuronal totalmente conectada.

Fuente: Ponce, 2010

### 2.2.2.2. CAPA DE ENTRADA

Es la capa que tiene como función la de recibir información externa, es decir, recibe los datos de entrada para resolver el problema. Sus características son:

- Ser de carácter único.
- Tiene un número de neuronas definido por la cantidad de entradas.
- Propaga los datos a la capa siguiente, por lo que en esta capa no se realiza ningún proceso, salvo la aplicación de una función escalar a través de las funciones de activación.

### 2.2.2.3. CAPA OCULTA

Es la capa donde se procesan los datos del problema de análisis. Sus características son:

- No posee carácter de única, por lo que puede existir más de una en la arquitectura de red.
- Posee un número de neuronas determinado por quien aplica la red.
- Los datos se propagan a la capa siguiente previo acto de una función de activación.
- Esta capa no posee conexión directa con el entorno o exterior.

### 2.2.2.4. CAPA DE SALIDA

Es la capa formada por las neuronas que proporcionan la respuesta al problema en cuestión, es decir, donde se presenta el resultado entregado por la Red Neuronal. Sus características son:

- Ser de carácter única.

- Posee un número de neuronas definido por la cantidad de outputs.
- En esta capa, las neuronas aplican una función de activación o de transferencia a los datos recibidos, antes de entregar el producto final.
- En los modelos más simples hay una sola salida.

### 2.2.3. FUNCIÓN DE ACTIVACIÓN

La función activación calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral,  $\Theta_i$ ) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1).

La función activación, es una función de la entrada global menos el umbral

Las funciones de activación más comúnmente utilizadas se detallan a continuación:

1) Función lineal:

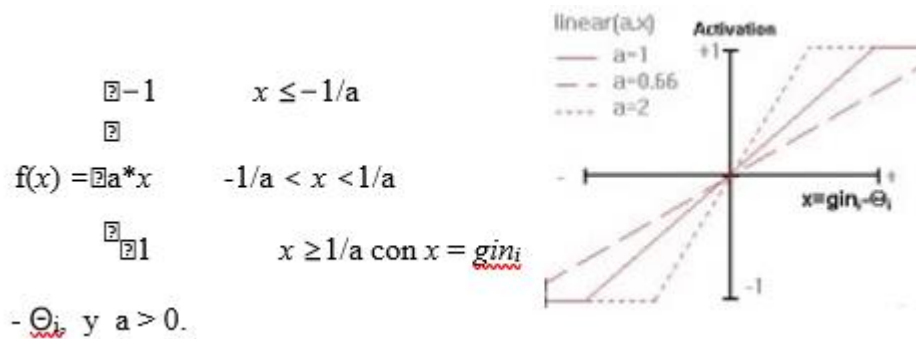


Figura 2: Función de activación (función lineal)

Fuente: Haykin, Simon (1998).

Los valores de salida obtenidos por medio de esta función de activación serán:

$a \cdot (gini_i - \Theta_i)$ , cuando el argumento de  $(gini_i - \Theta_i)$  (ver Figura 2), función de activación lineal, esté comprendido dentro del rango  $(-1/a, 1/a)$ .

Por encima o por debajo de esta zona se fija la salida en 1 o -1, respectivamente. Cuando  $a = 1$  (siendo que la misma afecta la pendiente de la gráfica), la salida es igual a la entrada.

2) Función sigmoidea (ver Figura 3):

$$f(x) = \frac{1}{1 + e^{-gx}}, \text{ con } x = gin_i - \Theta_i.$$




Figura 3: Función de activación (sigmoideal)

Fuente: Haykin, Simon (1998).

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.

3) Función tangente hiperbólica (ver Figura 4):

$$f(x) = \frac{e^{gx} - e^{-gx}}{e^{gx} + e^{-gx}}, \text{ con } x = gin_i - \Theta_i.$$




Figura 4: Función de activación (tangente hiperbólica)

Fuente: Haykin, Simon (1998).

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.

## 2.2.4. FUNCIÓN DE SALIDA

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona  $i$  ( $out_i$ ); por ende, la función de salida determina que valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente.

Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango  $[0, 1]$  o  $[-1, 1]$ . También pueden ser binarios  $\{0, 1\}$  o  $\{-1, 1\}$ .

Dos de las funciones de salida más comunes son:

Ninguna: este es el tipo de función más sencillo, tal que la salida es la misma que la entrada. Es también llamada función identidad.

- Binaria: 
$$\begin{cases} 1 & \text{si } act_i \geq \xi_i \\ 0 & \text{de lo contrario} \end{cases}$$
, donde  $\xi_i$  es el umbral.

Esquemáticamente, una neurona artificial quedaría representada como en la Figura 5




Figura 5: Representación de una red neuronal artificial

Fuente: [Tawfiq+99]

## **2.2.5. ETAPAS PARA LA CREACIÓN DE UNA RNA**

### **2.2.5.1. APRENDIZAJE O ENTRENAMIENTO**

En el contexto de las redes neuronales el aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red [Yao, 1995]. Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea.

El proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación suficientemente bueno. En términos más simples significa la extracción de regularidades de los datos de entrenamiento que serán transferidos a nuevos ejemplos. Esto se hace a través de una cierta regla de aprendizaje (manera sistemática de cambiar los pesos), construido normalmente a partir de la optimización de una función de error o costo, que mide la eficacia actual de la operación de red.

En un proceso de aprendizaje la información contenida en los datos de entrada queda incorporada en la propia estructura de la Red Neuronal, estructura que almacena la representación de cierta imagen de su entorno.

El modo de aprendizaje es de gran importancia, debido a que una característica esencial de las Redes Neuronales Artificiales es que son sistemas entrenables, capaces de realizar un determinado tipo de procesamiento, aprendiéndolo a partir de un conjunto de ejemplos.

Básicamente, existen tres aspectos relacionados con el aprendizaje: la elección del conjunto de entrenamiento y su tamaño, la elección de los parámetros del aprendizaje, y el momento en que debemos detener el aprendizaje.

Para enfrentar esto sólo existen algunas reglas generales, de manera que la experimentación juega un papel importante.

### **2.2.5.2. REGLA DE RETROPROPAGACIÓN.**

Existen diferentes algoritmos para entrenar las redes, siendo fundamental el de Retropropagación del Error, Backpropagation o Regla del Gradiente. Este algoritmo permite modificar los pesos de cada una de las neuronas de la red en forma proporcional al error de su salida (generalmente la diferencia entre lo deseado y lo obtenido), el cual por medio de la regla se va propagando desde la salida final por las capas intermedias hasta la entrada. Los pasos a seguir para este entrenamiento son los siguientes:

- Aplicar un vector de entrada como estímulo para la capa de entrada.
- Propagar esta señal por todas las capas de la red hasta obtener una salida.
- Comparar la salida de la red con el output deseado.
- Calcular una señal de error para cada unidad de salida.
- Transmitir la señal de error hacia atrás a todos los nodos que estén conectados directamente.
- Los nodos de capas anteriores reciben una fracción del error proporcional al peso de su conexión. Actualizar iterativamente los pesos de todas las conexiones de tal manera de disminuir el error.
- En el caso de que no se tenga convergencia, repetir todo lo anterior. Cuando el error resulta aceptablemente pequeño, el aprendizaje se da por concluido.

### **2.2.6. ELECCIÓN DEL CONJUNTO DE ENTRENAMIENTO**

El tamaño del conjunto de entrenamiento es de vital importancia para la utilidad práctica de la red. Si los patrones de entrenamiento no transfieren todas las características del problema, el mapeo descubierto durante el entrenamiento sólo se aplica al conjunto de entrenamiento. Así, el rendimiento en el conjunto de prueba será inferior al rendimiento del conjunto de entrenamiento. La única regla general es usar muchos datos y que sean representativos, es decir, datos que cubran todos los escenarios posibles con los que se pueda encontrar la red en el futuro.

La relación entre el tamaño y el conjunto de entrenamiento y el número de pesos de las Red Neuronal juega un papel importante. Si el número de ejemplos de entrenamiento es menor que el número de pesos, se podría producir una memorización de la solución, es decir, que la red almacene cada ejemplo del conjunto de entrenamiento, lo que se traducirá en una pobre generalización (capacidad de proporcionar una respuesta correcta ante datos no utilizados en su entrenamiento).

Es recomendable que el número de muestras de entrenamiento sea de al menos el doble que el número de pesos de la red. Siempre se puede esperar una caída en el rendimiento (más o menos entre 10% a 15%) desde el conjunto de entrenamiento al de prueba.

#### 2.2.7. TAMAÑO DE LA RED

La forma más eficiente para determinar el tamaño óptimo de la red es a través de la experimentación. Un parámetro importante es el número de neuronas en la capa oculta, el cual está relacionado con la capacidad del mapeo de la red. Mientras más grande es su número, mayor es su capacidad para memorizar el conjunto de entrenamiento.

Sin embargo, si se continúa aumentando el tamaño de la red, hay un punto donde la generalización empeorará, debido al hecho que se puede sobre ajustar el conjunto de entrenamiento, de modo que cuando la red trabaja con patrones que nunca ha visto anteriormente la respuesta es impredecible.

El problema es encontrar cuál es la combinación correcta de neuronas y el número de capas para resolver el problema en tiempos de entrenamiento más bajo. Cada capa aumenta el poder discriminante de la red.

#### 2.2.8. PARÁMETROS DE APRENDIZAJE.

El objetivo es entrenar tan rápido como sea posible y alcanzar el mejor rendimiento. Aumentando el parámetro de la tasa de aprendizaje, se disminuirá el tiempo de entrenamiento, pero también aumentarán las posibilidades de divergencia, es decir, de alejarse del valor óptimo. Debido a que



la corrección del peso depende de las características de la superficie de error y de la tasa de aprendizaje, para obtener un aprendizaje constante es necesario un parámetro adaptativo.

Se recomienda una estrategia en donde la tasa de aprendizaje sea grande al comienzo del proceso de aprendizaje y que progresivamente decaiga hacia el término de la adaptación.

La curva del error cuadrático medio (ECM) como función del número de iteraciones es llamada “curva de aprendizaje”. Cuando la curva de aprendizaje presenta una forma horizontal, el tamaño del paso (parámetro que determina la magnitud en la cual se van a actualizar los pesos) debería ser incrementado para acelerar el aprendizaje y mejorar su rendimiento.

Por otro lado, cuando la curva de aprendizaje presente una forma oscilatoria, el tamaño del paso debiera ser disminuido. En un caso extremo, el error aumenta uniformemente, mostrando que el aprendizaje es inestable. En este punto la red debería ser reformulada.

### **2.2.9. CLASIFICACIÓN DE LAS RNA**

En la literatura de las redes neuronales se encuentran muchas formas de clasificación. A continuación, se menciona la taxonomía más acorde con el problema estudiado [Charytoniuk+00].

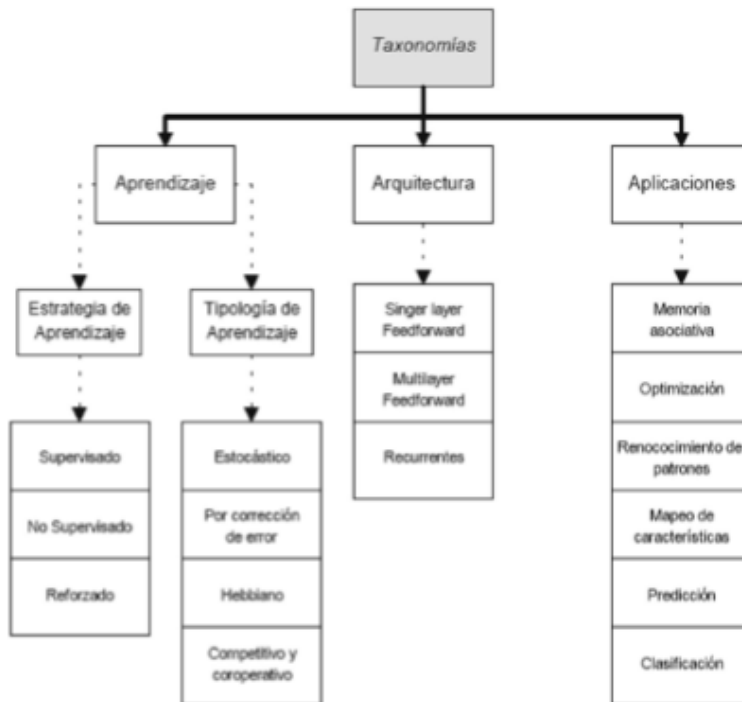


Figura 6: Taxonomía de las redes neuronales según ciertos parámetros

Fuente: [Charytoniuk+00]

En la Figura 6 se muestra un cuadro con la taxonomía general de las redes neuronales que permite distinguir la ubicación en la que se encuentra el tema de predicción con RNA.

Los elementos básicos comentados se pueden conectar entre sí para dar lugar a las estructuras neuronales o modelos conexionistas que podríamos clasificar de diferentes formas según el criterio usado. [Charytoniuk+00]:

a) Según su arquitectura, se clasifican en:

- *Redes Neuronales Monocapas*. Se corresponde con la red neuronal más sencilla ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diferentes cálculos.
- *Redes Neuronales Multicapa*. Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida.

- *Redes Neuronales recurrentes.* Esta red viene caracterizada por la existencia de lazos de realimentación. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o entre una misma neurona.
- b) Según su aprendizaje, se clasifican en:
- *Aprendizaje Supervisado.* En este rubro se clasifican las redes neuronales que tienen un supervisor en el desarrollo de la red, significa que existe un parámetro de referencia el cual es comparado con las salidas de la red.
  - *Aprendizaje No Supervisado.* Estos tipos de redes no tienen una referencia de comparación por lo cual contemplan la autoorganización, autoasociación, como proceso de obtención de la salida de la red.
- c) Según su aplicación, se clasifican en:
- *Redes de Clasificación.* Las redes de clasificación hacen uso del aprendizaje no supervisado para obtener patrones de clasificación a base de las entradas del problema.
  - *Redes de predicción.* Las redes de predicción tienen como objetivo modelar una función no lineal.

Otros tipos son redes de memoria asociativa, mapeo de características, reconocimiento de patrones y optimización.

## **2.2.10. PERCEPTRÓN MULTICAPA**

MLP son redes unidireccionales entrenadas con el algoritmo de propagación hacia atrás (Backpropagation o BP). Son redes con aprendizaje supervisado, de manera que requieren una respuesta deseada para ser entrenadas. Son ampliamente usados para clasificar patrones.

Usan eficientemente la información contenida en los datos de entrada. Estos modelos actúan como funciones mapeadoras universales, desempeñándose muy bien con las series de tiempo.

Es por ello que, aunque no sea la solución óptima en muchos casos, sobre todo por su elevado tiempo de entrenamiento en estructuras complejas, esta red está ampliamente extendida, teniendo aplicaciones en campos como:

- El reconocimiento del habla
- El reconocimiento óptico de caracteres
- El control de procesos
- La predicción de series temporales
- La conducción de vehículos




Figura 7: Red Perceptrón Multicapa. Conexionado feed-forward

Fuente: [Werbo89]

La arquitectura del MLP (ver Figura 7) está basada en una red feed-forward o con conexiones hacia delante, en la que se disponen de 3 tipos de capas:

- La capa de entrada, en la que las neuronas actúan como buffer y no se disponen de pesos ni umbrales.
- Las capas ocultas.
- La capa de salida, que actúa como un buffer de salida.

Todas las neuronas de la red (excepto las de la entrada, en general) llevan asociado un umbral. Además, cada neurona de una capa tiene conexiones con todas las de la capa anterior, aunque puede suceder que en ciertos casos no sea así, y que el peso de una conexión sea 0, es decir, que no exista. El entrenamiento de este tipo de redes, es decir, su aprendizaje, se realiza utilizando el algoritmo de Retropropagación o Backpropagación.

### 2.2.11. SOFTWARE TENSORFLOW

TensorFlow es una plataforma informática para la compilación de modelos de aprendizaje automático. Ofrece diversos kits de herramientas que permiten crear modelos con el nivel de abstracción que se prefiera. Es posible usar API de nivel inferior para compilar modelos definiendo una serie de operaciones matemáticas. O bien, usar API de nivel superior (como `tf.estimator`) para especificar arquitecturas predefinidas, como regresores lineales o redes neuronales.

En la Figura 8, se muestra la jerarquía actual de los kits de herramientas de TensorFlow:

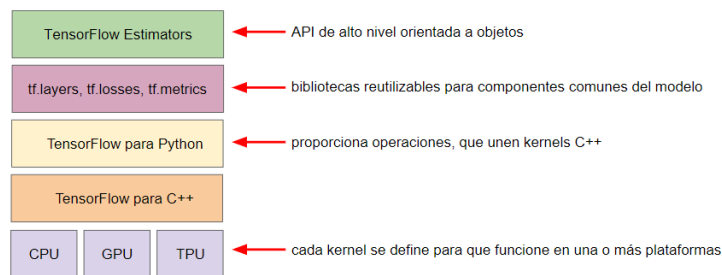


Figura 8: Jerarquía de los kits de herramientas de TensorFlow.

Fuente: <https://developers.google.com/>

### 2.2.12. MARCO LEGAL

Las políticas dirigidas al sector textil se encuentran dentro de los programas de desarrollo del estado a través del Ministerio de Desarrollo y Economía Plural, enfocados a la Industria Textil y dentro del Plan Nacional de Desarrollo que contribuye a la transformación de la matriz productiva para cambiar el actual patrón primario exportador excluyente.



Figura 9: Producción de manufactura.

Fuente: Instituto Nacional de Estadística – INE

Decreto Supremo No. 2765, 14 de mayo de 2016, Artículo 3°.- (Competencia institucional) El Servicio Nacional Textil - SENATEX está destinado a impulsar el cambio de la matriz productiva nacional a través del incremento de la agregación de valor a la producción primaria, transformación tecnológica, alza de la productividad, diversificación productiva y mayor generación de excedentes e ingresos en la producción textil, participando en la creación, consolidación, modernización y tecnificación de los emprendimientos productivos textiles del país (ver Figura 9).

La participación del sector textil, a lo largo de los últimos 19 años muestra una tendencia decreciente, es decir de 1.5% para el año 2000 baja a 0.6%, en el año 2018. El decrecimiento del valor agregado sectorial, su composición estructural, en relación al producto Industrial y al producto nacional, se ha reducido de manera significativa (ver Figura 10).



Figura 10: Participación del sector textil en el PIB.

Fuente Elaboración Propia en base a los datos del INE. 20019

## **CAPÍTULO III**

### **METODOLOGÍA DE LA INVESTIGACIÓN**

#### **3.1. MÉTODOS DE INVESTIGACIÓN**

El presente trabajo propone una metodología que involucra el uso de una técnica cuantitativa para el cálculo de pronósticos de demanda a partir de la información histórica de productos de línea textil comercializados en el mercado, y su posterior ajuste mediante la aplicación de un factor que califica la similitud entre el nuevo producto y el producto de referencia escogido.

La selección de la técnica de redes neuronales se debe a que está, permite descifrar patrones de comportamiento de una serie de datos, determinando la influencia de diversas variables de entrada (drivers de la demanda) sobre una variable de salida (demanda); en contraste con las series de tiempo tradicionales, que sólo consideran la demanda histórica [19].

Según la naturaleza de los datos esta investigación utiliza la metodología cuantitativa, ya que procura obtener información exacta y cuantificable del nivel de demanda para gestionar un aprovisionamiento efectivo y preciso de materias primas. La investigación cuantitativa se basa en el estudio y análisis de la realidad a través de diferentes procedimientos basados en la medición. Permite un mayor nivel de control e inferencia que otros tipos de investigación, siendo posible realizar experimentos y obtener explicaciones contrastadas a partir de hipótesis.

#### **3.2. TIPO DE INVESTIGACIÓN**

El presente trabajo de tesis, hará uso del tipo investigación descriptiva, que corresponde a la identificación de las características del problema propuesto basado en la observación y recopilación de información. Este método está diseñado para representar a los participantes de una manera muy sistemática y precisa. En resumen, consiste en describir el fenómeno, observarlo y extraer conclusiones de él.



Este método utiliza modelos matemáticos con los que se analizan los resultados pasados de las ventas de las empresas. Estos modelos suponen que los datos históricos son relevantes en el futuro, por lo tanto, es necesario conocer los datos de ventas pasados y los patrones de demanda.

### 3.3. UNIVERSO O POBLACIÓN DE ESTUDIO

Se realizará el estudio acerca de la demanda de indumentaria de vestir comercializadas por el sector textil (ver Figura 11), específicamente para empresas establecidas en el eje central, y cómo influyen las variables en los patrones de demanda de los productos textiles, el pronóstico se llevará a cabo para las líneas de productos textiles de tipo algodón, hilanderías y tejido plano, mismos que representan la mayor demanda en el mercado.

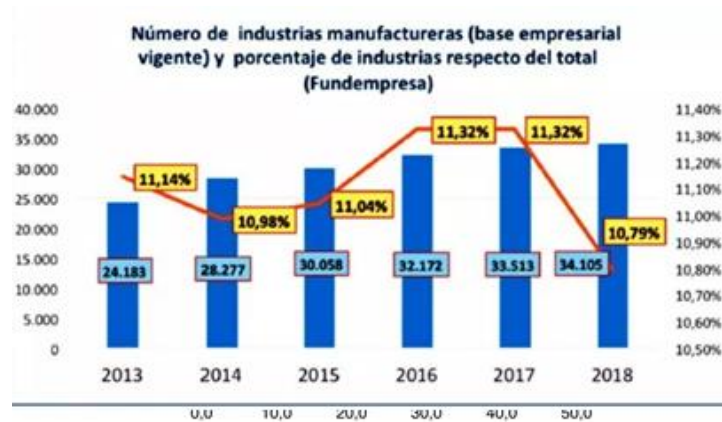


Figura 11: Número de empresa manufactureras

Fuente. FUNDEMPRESA – 2018

La definición del universo o población de estudio, se centra en:

1. Empresas del sector textil
2. Responsables de planificación y producción de planta de empresas textiles
3. Tipo de textiles con mayor demanda (ver Figura 12)
4. Demanda de productos textiles por mes y año

La industria textil es aquella área de la economía que se encuentra abocada a la producción de telas, fibras, hilos y asimismo incluye a los productos derivados de éstos.

Se identificaron las siguientes empresas dedicadas al rubro textil (Tabla 5).

Tabla 5: Empresas del sector textil

N°	Empresas textiles	Ubicación
1	ABSTRATUM	c. Velasco Nro. 548 - Santa Cruz de la Sierra, SANTA CRUZ
2	ALMANZA	Av. San Martín Nro. 398 (Central) - Cochabamba, COCHABAMBA
3	AMERICA TEXTIL S.A. "AMETEX"	c. Yanacachi Nro. 1489 (Villa Fátima) - La Paz, LA PAZ
4	ASEA LTDA. INDUSTRIAS TEXTILES	c.Narciso Dulon Nro. 516 (Villa Fátima) - La Paz, LA PAZ
5	BLONDEL S.R.L.	c. Manuel Mariaca Nro.1610 (Miraflores) - La Paz, LA PAZ
6	BOGUS LTDA.	c. Narciso Dulon Nro. 516 - La Paz, LA PAZ
7	CIENSA LTDA.	Av. Manco Kapac Nro. S-0592 (Ex Matadero) - Cochabamba, COCHABAMBA
8	CINTATEX	Calle 4 Nro. 55, Urbanización Los Álamos - Sucre, CHUQUISACA
9	CONFECCIONES CORCEL S.R.L.	Av. Uyuni Nro. 1217 - Cochabamba, COCHABAMBA
10	CONFECCIONES LA ANDALUZA	Edif. Laborada P.1 OF. 105 Loayza esq. Juan de la Riba - La Paz, LA PAZ
11	CONFECCIONES MITSUBA	Parque Industrial Modulo 2 Mza. 20 - Santa Cruz de la Sierra, SANTA CRUZ
12	CONFECCIONES NICO J&L	Aniceto Arce Nro. 296 - Sucre, CHUQUISACA
13	CONFECCIONES ROMY	Pablo Roca Nro. 96 esq. 26 de Febrero - Santa Cruz de la Sierra, SANTA CRUZ
14	CONFECCIONES SERVICIOS EPRIM	Av. Siglo XX s/n - Cochabamba, COCHABAMBA
15	CONTEXBOL	Barrio los Olivos c. 5 Nro. 12 - Santa Cruz de la Sierra, SANTA CRUZ
16	COOPERATIVA ARTESANAL PECORELLA LTDA	Av. Tiquipaya km. 1 - Cochabamba, COCHABAMBA
17	COOPERATIVA INTEGRAL FOTRAMA LTDA.	Av. Circunvalacion Nro. 413 - Cochabamba, COCHABAMBA
18	CURTIEMBRE ANDINA LTDA.	Av. Jaimes Freyre Nro. 2550 (Sopocachi) - La Paz, LA PAZ
19	CURTIEMBRE UNICUERO S.R.L.	Urb. Pucarani Manzano 7 Nro. 220 - El Alto, LA PAZ
20	DELTA TRADERS MANUFACTURING CO. (P. DE LAS GORRAS)	Santa Cruz
21	DINAMICA TEXTIL LTDA.	c. Estados Unidos nro. 1458 (Miraflores) - La Paz, LA PAZ
22	FAB. DE SOMBREROS SUCRE SERCIS SRL.	Inca Garcilazo Nro. 134 - Sucre, CHUQUISACA
23	FABRICA DE CONFECCIONES RECORD LTDA.	Av. Tte. Wálter Vega Nro. 81 - Santa Cruz de la Sierra, SANTA CRUZ
24	FABRICA DE CONFECCIONES TRIAL	c. Teniente Vega Nro. 79 Edif. confecciones record - Santa Cruz de la Sierra, SANTA CRUZ
25	FABRICA DE TEJIDOS DE PUNTO "ROSARIO"	c. Milliguaya Nro. 1155 (Villa Fátima) - La Paz, LA PAZ
26	FABRICA DE TRENADOS Y CINTAS LIBERTY S.A.	Av. Blanco Galindo km. 6.5 - Cochabamba, COCHABAMBA
27	FABRICA TEJIDOS "YUAN TUNG" S.R.L.	Av. Baltazar de Salas c. Mayor Vasquez Nro. 950 (Vino Tinto) - La Paz, LA PAZ
28	FABRICA TEJIDOS SANTA ROSA	c. 26 de Mayo Nro. 786, Villa Mariscal Santa Cruz - La Paz, LA PAZ
29	FRATEXA S.R.L.	Parque Industrial Mza. 5 - Santa Cruz de la Sierra, SANTA CRUZ
30	GAV SPORT	c. Socabaya Nro.326 (Central) - La Paz, LA PAZ
31	GLAMER S.R.L.	Av. Saavedra Nro. 2348 (Miraflores) - La Paz, LA PAZ
32	GREMINGER SOCIEDAD INTERNACIONAL GRESI S.R.L.	Barrio Equipetrol c. 7 Oeste Nro. 30 - Santa Cruz de la Sierra, SANTA CRUZ
33	HILANDERIAS BOLIVIANAS "HILBO" S.A.	Carretera a Oruro KM. 17 - El Alto, LA PAZ
34	Imtex SRL	Av. Camino a Yupaca No. 160 Zona Allacacho-Achocalla
35	INASO LTDA.	Av. Uyuni Nro. 1217 - Cochabamba, COCHABAMBA
36	INDUSTRIA Y COMERCIO LITORAL - FRANCISCA MAMANI MOYA	Av. Illimani Nro.1833 - La Paz, LA PAZ
37	JANA S.R.L.	c. Genaro Sanjinez Nro. 367 (Central) - La Paz, LA PAZ
38	JEMA & COMPANY	Av. Ayacucho final Sud Nro. 1184 (La Cancha) - Cochabamba, COCHABAMBA
39	JULYO'S	Obispo Anaya Nro. 260 - Cochabamba, COCHABAMBA
40	LA COMITA	Av. Camacho - Potosí, POTOSÍ
41	LA POLONESA S.R.L.	c. Murillo Nro. 650 (Frente al colegio Ingles Católico) - La Paz, LA PAZ
42	LLAMACTIVA	Aroma Nro. 582 - Oruro, ORURO
43	MANUFACTURAS CBBA	c. 25 de Mayo Nro. s-0635 - Cochabamba, COCHABAMBA
44	MANUFACTURAS TEXTILES "ANDINA" S.R.L.	c.Federico Suazo Nro. 1995 (Central) - La Paz, LA PAZ
45	MANUFACTURAS TUFTING LIMITADA	Pasaje Cordero Nro. 135 (San Jorge) - La Paz, LA PAZ
46	MAQUITEX	c. Postrer Valle Nro. 107 - Santa Cruz de la Sierra, SANTA CRUZ
47	NATURAL	Av. 6 de Octubre Nro. 4741 - Oruro, ORURO
48	NOVARA S.R.L.	c.14 Nro. 555 (Obrajes) - La Paz, LA PAZ
49	PULLMAN INDUSTRIA Y COMERCIO S.R.L.	Av. 20 de Octubre Nro.2072 Edif. Atahualpa P.B. OF. 1 - La Paz, LA PAZ
50	SENDETEX LTDA.	Av. Blanco Galindo km. 6.5 - Cochabamba, COCHABAMBA
51	SOCIEDAD INDUSTRIAL Y COMERCIAL CURMA SRL.	c. Mamá Ocllo Nro. s-0892 - Cochabamba, COCHABAMBA
52	TALLER DE CONFECCIONES ALPACH	Av. Costanera Nro. 280 (Villa la Merced) - La Paz, LA PAZ
53	TASTEX LTDA.	c. Litoral Nro. 1261 (Miraflores) - La Paz, LA PAZ
54	TEXTILES CAPINOTA S.R.L.	Av. Blanco Galindo km. 10.5 - Cochabamba, COCHABAMBA
55	VULTEXIBER LTDA.	Av. 6 de Marzo Nro. 88, Carretera a Oruro KM. 2 - El Alto, LA PAZ

Fuente: IBCE - Instituto Boliviano de Comercio Exterior

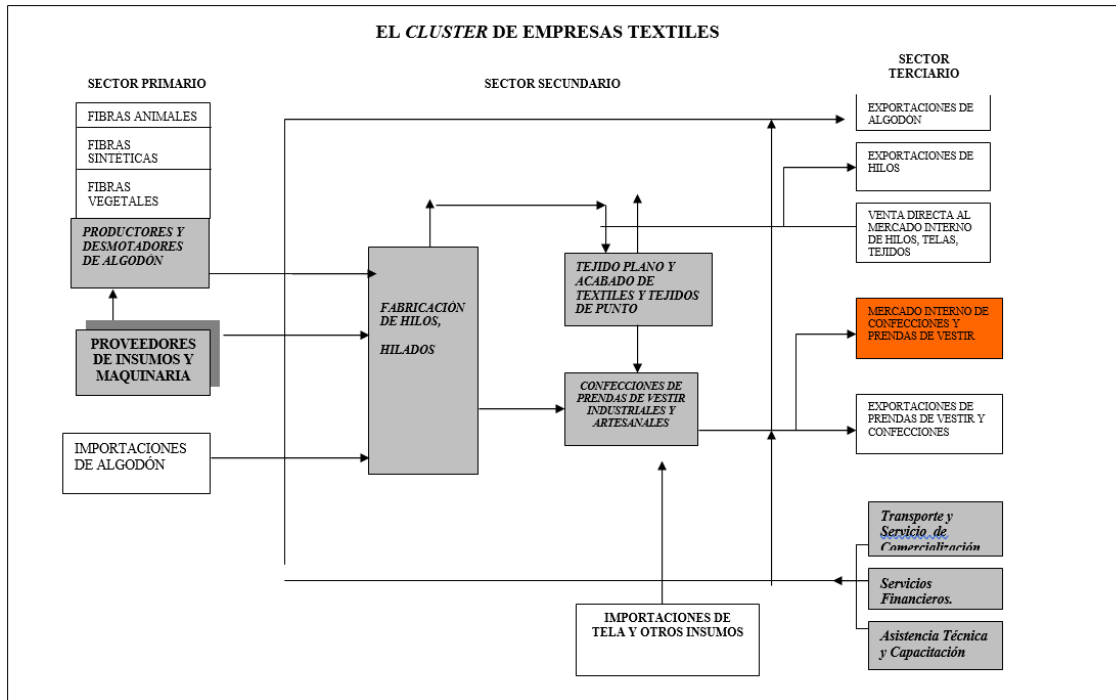


Figura 12: Clúster de textiles

Fuente. Elaboración propia basada en datos Instituto Nacional de Estadísticas INE

### 3.3.1. DETERMINACIÓN Y ELECCIÓN DE LA MUESTRA

Las empresas producen los bienes tanto para el mercado interno como para la exportación.

Existen muchas pequeñas empresas que se dedican a la confección y que no están registradas oficialmente constituyendo el grueso de las empresas textiles ubicadas en el país (Tabla 5).

Los requerimientos de materia prima son cubiertos con la importación (legal o de contrabando). Dentro de los diferentes tipos de producción textiles, de acuerdo a la Tabla 6, el presente trabajo concentra su investigación en el rubro textil abocado a productos de Algodón, Hilandería y Tejido Plano por ser el mayor producto en manufactura (ver Figura 13).

A continuación, se muestra el gráfico con el detalle de los productos señalados como elegidos.

ESQUEMA SIMPLIFICADO DEL CLUSTER DE TEXTILES Y CONFECCIONES EN BOLIVIA

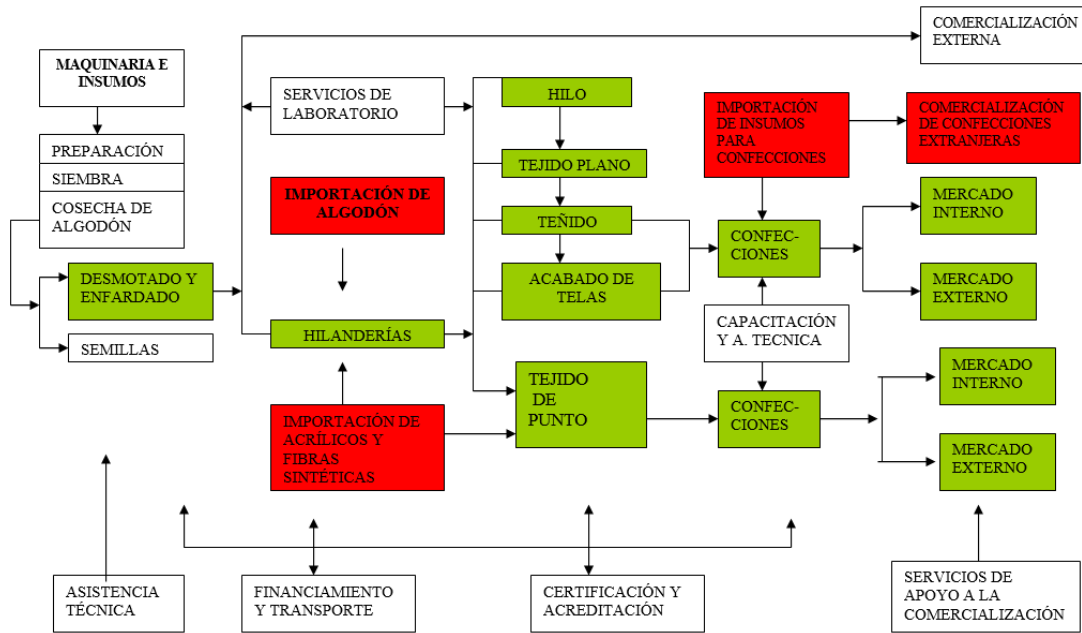


Figura 13: Clúster de textiles

Fuente. Elaboración propia basada en datos Instituto Nacional de Estadísticas INE

Se aplica un muestreo aleatorio a ser analizado según la demanda requerida de la población según la oferta descrita en la Figura 14.

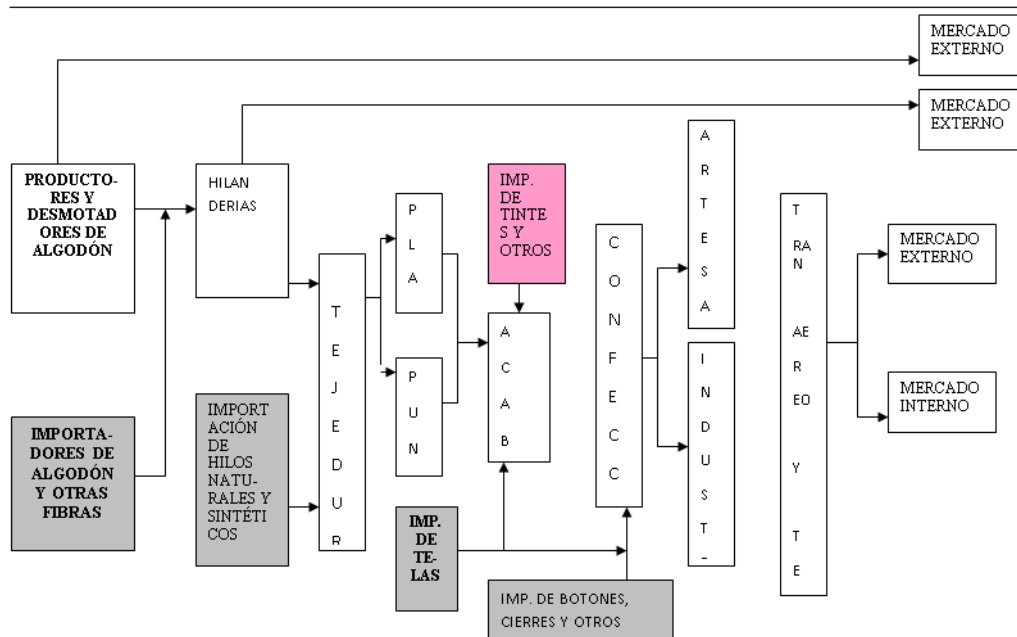


Figura 14: Tipo de productos para la muestra

Fuente. Elaboración propia basada en datos Instituto Nacional de Estadísticas INE

Por lo tanto, se establece la siguiente relación descrita en la Tabla 6.

A continuación, se describen los productos textiles que formarán parte de la muestra.

Tabla 6: *Tipos de producción textil*

TIPOS DE PRODUCTOS	CONDICIONES DE LA DEMANDA
Productoras de Algodón	<ul style="list-style-type: none"> <li>• Exigente en volúmenes, calidad y tiempo de entrega</li> <li>• Los déficits de demanda se cubren con oferta extranjera.</li> <li>• Creciente si se logra mayor integración a la cadena</li> </ul>
Hilanderas	<ul style="list-style-type: none"> <li>• La mayor parte de la producción de hilos responde a sus propias necesidades de confección de prendas de vestir</li> <li>• Toda la producción orientada a demandas del exterior</li> <li>• Coordinación vertical y procesos de subcontratación para atender la demanda</li> </ul>
Tejedoras de Tejido Plano	<ul style="list-style-type: none"> <li>• Tendencia de caída en las ventas desde 1998</li> <li>• La demanda ha disminuido por la presencia de telas chinas en nuestros mercados, internadas legalmente o por vía del contrabando</li> </ul>
Tejedoras de Tejido de Punto	<ul style="list-style-type: none"> <li>• Los niveles de pobreza de nuestra sociedad hacen que la gente priorice el precio mas que la calidad</li> <li>• El contrabando y la ropa usada han restringido la participación de mercado de las industrias nacionales</li> </ul>
Confeccionistas Industriales	<ul style="list-style-type: none"> <li>• Exigente crecimiento y sujeta a parámetros internacionales.</li> <li>• Demanda externa creciente y sujeta a fuertes presiones de competidores de otros países.</li> </ul>
Confeccionistas Artesanales	<ul style="list-style-type: none"> <li>• Consumidores de altos ingresos y conocedores de las características del producto.</li> <li>• Demanda externa como foco de los esfuerzos de los artesanos.</li> </ul>

Fuente. Elaboración propia basada en datos  
IBCE - Instituto Boliviano de Comercio Exterior

Para llevar adelante una correcta investigación se debe calcular el tamaño muestral mínimo necesario para detectar un determinado patrón.

### 3.3.1.1. RELACIÓN ENTRE ERROR Y TAMAÑO DE MUESTRA

Se debe considerar que el margen de error, nivel de confianza y tamaño de la muestra siempre van en estrecha unión. Si se busca obtener un margen de error y un nivel de confianza determinados (por ejemplo, error del 5% con confianza 95%) necesitaremos un tamaño de muestra mínimo correspondiente.

Modificar cualquiera de los 3 parámetros, altera los restantes:

1. Reducir el margen de error obliga a aumentar el tamaño de la muestra.
2. Aumentar el nivel de confianza obliga a aumentar el tamaño de la muestra.
3. Si aumenta el tamaño de mi muestra, puedo reducir el margen de error o incrementar el nivel de confianza.

Para obtener un tamaño de muestra eficiente, se utilizará el teorema del límite central, conociendo la propiedad anterior, es sencillo adaptar las fórmulas de la distribución gaussiana a cualquier caso (sea cual sea la media y desviación). Se verá con detalle el caso de la estimación de una proporción.

Para ello usamos la siguiente fórmula:

#### *Tamaño de muestra*

Donde:

$n$  = El tamaño de la muestra que se calculará

$N$  = Tamaño del universo (tipos de productos)

$Z$  = Es la desviación del valor medio que se acepta para lograr el nivel de confianza deseado. Los valores más frecuentes son:

Nivel de confianza 90% ->  $Z=1,645$

Nivel de confianza 95% ->  $Z=1,96$

Nivel de confianza 99% ->  $Z=2,575$

Si se busca englobar los valores que cubren el 95% de los casos, tenemos que definir un margen de error entre -1,96 y +1,96 de la media. Si queremos cubrir el 99% de los casos, el margen debe alejarse hasta +-2,58.

e = Es el margen de error máximo que admitimos (5%)

p = Es la proporción que se espera encontrar. (40%) debido a que la información tiene un grado de certeza aceptable.

En una producción próxima a los 25.000 productos. por mes, y se requiere conocer qué porcentaje de ese producto será comercializado correctamente, con un margen de error del 5% y un nivel de confianza del 95%. En el supuesto de no tener ninguna información previa sobre cuál puede ser el tanto por ciento de propietarios que podemos obtener en la encuesta. En este caso es posible utilizar la fórmula simplificada pues 25000 productos > 20000 (se considera 20000 productos, como muestra enorme), y usaremos p=50% pues no se tiene información previa sobre el resultado esperado:

$$n = \frac{Z^2 \cdot p(1-p)}{e^2}$$

$$n = 1,96^2 * 0,5 * (1 - 0,5) / 0,05^2 = 384,16 \rightarrow 385$$

Por lo tanto, se debe tener una muestra de 385 productos para mantenerlos dentro de los niveles de error definidos.

### **3.4. SUJETOS VINCULADOS A LA INVESTIGACIÓN**

Lo sujetos vinculados a la investigación, son aquellos encargados de proporcionar la información de datos necesarias, así como aquellos a los que se debe acudir y observar para tener el conjunto completo de datos requeridos, la Figura 15, describe los sujetos requeridos.

<p><b>Empresas Textiles</b></p> <p>la industria textil es uno de los “fuertes” de la industria nacional, porque abarca el 22% del 32% de la productividad a nivel nacional.</p>	<p><b>Departamentos de Planificación</b></p> <p>Se ocupa de la elaboración de un plan a partir de un análisis exhaustivo de la situación de la empresa y de su entorno, en función del cual se establecerán los objetivos y las estrategia más apropiada para alcanzar el éxito</p>
<p><b>Detalle de Productos</b></p> <p>Detalle de tipos de productos producidos en las empresas y de los cuales se tiene el detalle de ventas historicas, mediante los cuales se realiza el pronóstico.</p>	<p><b>Departamentos de Producción</b></p> <p>Los Departamentos de producción, también llamada área o departamento de operaciones, manufactura o de ingeniería, es el área o departamento de un negocio que tiene como función principal, la transformación de insumos o recursos (energía, materia prima, mano de obra, capital, información) en productos finales (bienes o servicios).</p>

Figura 15: Sujetos vinculados a la investigación

Fuente. Elaboración propia

Se considera a las empresas textiles como el principal sujeto de vinculación con el presente trabajo, siendo que la participación del sector textil, a lo largo de los últimos 19 años muestra una tendencia decreciente, es decir de 1.5% para el año 2000, baja a 0.6%, en el año 2018.

Asimismo, el rol de los responsables de producción es sumamente importantes en el presente trabajo, siendo sus principales tareas:

- Ajusta la planificación en función del nivel de ventas.
- Transforma en órdenes de fabricación y de aprovisionamiento y decide cuándo y dónde se producirán dichas órdenes.
- Inicia procedimientos de planificación y busca beneficios a escala global.
- Planifica las operaciones en función de la demanda.



### 3.5. FUENTES Y DISEÑO DE LOS INSTRUMENTOS DE RELEVAMIENTO DE LA INFORMACIÓN

#### 3.5.1. FUENTES DE LA INVESTIGACIÓN

Las fuentes primarias de información identificadas son las siguientes:

- Entrevistas y cuestionarios realizados al personal de las empresas textiles (ver Figura 16).
- Información proporcionada por empresas textiles (Unidades de Planificación), respecto a la demanda de sus principales productos de venta, Tabla 7.
- Información recogida de la Cámara Nacional de Industrias de Bolivia 2019.
- Instituto Nacional de Estadística. 2017. Anuario Estadístico, Instituto Boliviano de Comercio Exterior IBCE. (2005).

Tipo de entrevista para pronosticar la demanda de productos textiles	
1. Datos Personales	
Datos de personal de planificación	Jefe de Planificación
Nombre:	(Denominación)
Objetivo: Obtener las variables actuales con las que cuenta el experto para poder hallar la cantidad de demanda de productos textiles de algodón y poder añadir otras variables que se consideran necesarias según su experiencia.	
Descripción: Se mencionarán variables teóricas que han sido comprobadas mediante estudios técnicos, que influyen directamente en el pronóstico de productos generales y otras variables que se deben seleccionar igualmente puesto que son influyentes en el proceso de pronóstico de productos textiles que son consideradas aptas para tomarse en cuenta.	

Figura 16: Tipos de entrevistas realizadas a personal de planificación.  
Fuente. Elaboración propia

Tabla 7: Entrevista pronóstico de demanda

	<input type="checkbox"/>	consumido.
Publicidad del bien sustituto	<input checked="" type="checkbox"/>	La publicidad del bien sustituto influye en la demanda de nuestro producto ya que cuando hay mas publicidad del producto competente nuestras ventas disminuyen
Publicidad del bien complementario	<input type="checkbox"/>	
Periodo de pronóstico	<input checked="" type="checkbox"/>	En nuestro caso, la compra de productos farmacéuticos es una vez al mes, y a la vez muchos de ellos dependen de la estación, por tanto el mes es importantes.
Intensidad de la publicidad	<input type="checkbox"/>	

Variables a considerar		Observación
Existencia de la promoción del producto	<input checked="" type="checkbox"/>	Se toma en cuenta en la empresa para predecir el siguiente stock.
Tiempo de la promoción	<input checked="" type="checkbox"/>	También se toma en cuenta
Existencia de la promoción del bien sustituto	<input checked="" type="checkbox"/>	Tenemos en cuenta a la competencia, porque su promoción puede influir en nuestra venta.
Tiempo de la promoción del bien sustituto	<input checked="" type="checkbox"/>	La misma explicación
	<input type="checkbox"/>	

Variables Consideradas		Observación
Publicidad de productos	<input checked="" type="checkbox"/>	La publicidad del producto es muy determinante para la venta, se transmite por algún medio o por referencias de especialista e incluso de persona que lo han

Fuente. Elaboración propia

### 3.5.2. DISEÑO DE LOS INSTRUMENTOS DE RELEVAMIENTO DE LA INFORMACIÓN

El diseño de los instrumentos requeridos para el relevamiento de la información es el siguiente:

- Entrevistas con personal asignado al área de planificación, a objeto de obtener variables actuales con las que cuenta el experto para hallar la cantidad de demanda de productos textiles y poder añadir otras variables que se consideran necesarias según su experiencia.
- Obtención de documentación relacionada al índice de ventas (datos históricos) de los productos con mayor demanda de las empresas (Anexo 3).
- Verificación de parámetros requeridos para pronosticar la demanda.

Se efectuaron encuestas específicas al personal de planificación a objeto de determinar la capacidad instalada de equipamiento, siendo la encuesta la siguiente:

### 3.5.2.1. ENCUESTAS RESPECTO A LOS PRODUCTO

Las preguntas planteadas a responsables de producción o de planta de las empresas textiles fueron (Tabla 8):

Tabla 8: *Entrevista a personal de producción.*

Preguntas planteadas	Nombre de contacto / Título	Forma de registro	Grupo de respuestas
¿Cuántas líneas de productos se desarrollarán?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Se desarrollaran 2 lineas de producción 2. Se continuará con la linea de Producción actual 3. Se verificará la capacidad de materias primas
¿Cuál es la calidad de la materia prima que se utilizará?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Algodón frizado 2. Algodón de fibra 3. Hilo de gramaje
¿Cuáles son los productos complementarios?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Se instalaran productos ya establecidos 2. De acuerdo a demanda y material específico
¿Cuál es la máxima capacidad de producción?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Entre 10 a 200 toneladas
¿Cuál es la capacidad para diseñar nuevos productos?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. De acuerdo a requerimiento y gramaje 2. De acuerdo a capacidad de compra de materias primas 3. De acuerdo a tamaño de pedido
¿Con qué tipo de maquinaria se cuenta?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Tejido Plano 2. Tejido circular 3. Tejido Ketten
¿Cómo se realizará el control de calidad?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	
¿Cuáles son los tamaños adecuados?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. 180 Mts. 2. 1500 Mts 3. 3000 Mts.
¿Qué tipo de empaque se utilizará?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Empaque con papel 2. Empaque rígido 3. Empaque flexible
¿Qué forma tendrá el producto?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Producción de fibras 2. Producción de fibras. 3. Fibra natural y fabricación de fibra sintética. 4. Hilandería. 5. Tejeduría. 6. Tintorería y acabados
¿Qué marca tendrá el producto?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Las marcas estan previamente definidas salvo nuevos requerimientos
¿Qué colores se producirán?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Los colores son diversos y definidas por el area de Química industrial
¿En qué estilos?	Jefe de Planta, Producción, Operarios, Técnicos	Visitas personales, correos electrónicos	1. Fibras textiles 2. Lino 3. Lana 4. Algodón 5. Seda 6. Fibras sintéticas

Fuente: Elaboración propia, basado en entrevistas.

### 3.5.2.2. ENCUESTAS RESPECTO AL PRECIO

Tabla 9: *Entrevista a personal de planificación.*

Preguntas planteadas	Nombre de contacto / Título	Forma de registro	Grupo de respuestas
¿Cuáles son los criterios para la fijación de precios?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es el margen por producto y línea?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es la estructura de costos de la empresa?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es el costo fijo de la empresa?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿cuál es el costo de cada producto?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es el nivel de ventas requerido a X precio para que la empresa cubra los costos totales?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuáles son los precios de la competencia por un producto similar?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es el punto de equilibrio (CF/P-KB)?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál es la política de venta a crédito?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Tiene posibilidades de reducir costos?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	
¿Cuál será el plazo o tasa de interés cobrada a clientes?	Jefe de Planificación, Marketing, Administración, Economía, Técnicos.	Visitas personales, correos electrónicos	

Fuente: Elaboración propia, basado en entrevistas.

## **3.6. PROCESAMIENTO Y ANALISIS DE LA INFORMACIÓN**

Se observó que el método de pronóstico de demanda actualmente utilizado en las empresas textiles se sustenta en técnicas estadísticas comunes, sin la incorporación de herramientas modernas y/o eficientes.

### **3.6.1. CREACIÓN DEL MODELO PREDICTIVO**

El modelo de pronóstico a utilizar debe comprender una serie de etapas descritas anteriormente, los pasos a seguir son:

#### **3.6.1.1. FORMULACIÓN DEL PROBLEMA Y RECOLECCIÓN DE DATOS**

El problema previamente definido corresponde a la escasa información que poseen las Direcciones o Unidades de Planificación, respecto a la demanda que debe realizarse y de ese modo las áreas de producción requieran aprovisionamientos únicamente necesarios.

#### **3.6.1.2. MANIPULACIÓN Y LIMPIEZA DE DATOS**

Repercute directamente en la calidad de información a ser utilizada en el pronóstico de la demanda, los datos deben contener:

- *Exactitud*: los datos deben cumplir los requisitos de integridad, consistencia y densidad, la información obtenida por parte de las empresas del sector textil, se basan en información estadística.
- *Integridad*: los datos deben cumplir los requisitos de entereza y validez.
- *Consistencia*: alcanzado por la corrección de contradicciones y anomalías sintácticas, se verificó la información constatando la misma con la de gestiones pasadas.
- *Uniformidad*: relacionado con irregularidades.
- *Densidad*: conocer el cociente de valores omitidos sobre el número de valores totales.
- *Unicidad*: relacionado con datos duplicados.

### 3.6.1.3. CONSTRUCCIÓN Y EVALUACIÓN DEL MODELO

El modelo considera:

- Se dispone de información histórica sobre la variable que se pronosticará
- La información puede cuantificarse
- Es razonable suponer que el patrón del pasado seguirá ocurriendo en el futuro. En estos casos puede elaborarse un pronóstico con un método de series de tiempo.
- El objetivo del método de suavización exponencial es descubrir un patrón en los datos históricos y luego extrapolarlo hacia el futuro; el pronóstico se basa sólo en valores pasados de la variable que tratamos de pronosticar o en errores pasados

### 3.6.1.4. APLICACIÓN DEL MODELO (EL PRONÓSTICO REAL)

Los modelos predictivos basados en suavizamiento exponencial, son ampliamente utilizados en las empresas textiles, principalmente por su facilidad de uso y al no requerir herramientas software de alto valor, el modelo posee cuatro (4) fases de trabajo:

#### FASE 1: OBTENCIÓN DE LOS DATOS

La primera fase del modelo utilizado se centra en la obtención de datos, cuantos más mejor. Sin embargo, los datos deben ser precisos y confiables.

- **Históricas:** Se poseen datos de las gestiones 2015, 2016, 2017 y 2018, previamente depuradas y validadas (ver Figura 17).
- **Actualizadas:** para poder comparar los datos reales con nuestras predicciones y así poder corregir el error y mejorar progresivamente el desempeño del modelo.
- **Homogéneas:** los datos fueron ordenados utilizando metodologías de obtención uniformes (Series de tiempo), y por tanto los datos son objetivos, para poder comparar variables entre sí.

El proceso de búsqueda, documentación, formateo y limpieza de datos suele ser el más tedioso de realizar, el dato de muestra corresponde a la gestión 2015.

Producto	ene-15	feb-15	mar-15	abr-15	may-15	jun-15	jul-15	ago-15	sep-15	oct-15	nov-15	dic-15
JERSEY - PRENDA DE VESTIR DE ALGODÓN	9,14	9,99	9,16	9,56	10,72	10,54	9,83	9,7	9,82	9,6	9,72	9,59
POLERA PIQUÉ - PRENDA DE VESTIR DE ALGODÓN	5,28	5,24	5,16	5,17	5,14	5,94	5,45	5,13	5,23	6,13	5,14	5,21
POLERA - PRENDA DE ALGODÓN INTERLOCK	53,83	54,8	55,17	60,55	58,86	63,32	59,84	6,96	60,41	61,25	60,52	6,48

Producto	ene-16	feb-16	mar-16	abr-16	may-16	jun-16	jul-16	ago-16	sep-16	oct-16	nov-16	dic-16
JERSEY - PRENDA DE VESTIR DE ALGODÓN	9,88	10,01	9,99	9,86	10,87	11,43	11,84	11,8	12,08	12,57	12,07	12,46
POLERA PIQUÉ - PRENDA DE VESTIR DE ALGODÓN	9,88	10,01	9,99	9,86	10,87	11,43	11,84	11,8	12,08	12,57	12,07	12,46
POLERA - PRENDA DE ALGODÓN INTERLOCK	5,24	5,25	5,46	5,37	5,44	5,62	5,84	5,88	6,03	6,21	6,09	6,19

Figura 17.: Datos obtenidos por la Empresa Textil

Fórmula de Suavizamiento Exponencial de Ventas

$$F = \alpha A + (1-\alpha) B$$

Donde:

**F** = Nuevo pronóstico

**$\alpha$**  = Constante de suavización

**A** = Demanda real del periodo anterior

**B** = Pronóstico del periodo anterior

De acuerdo al modelo predictivo, personal de planificación encargada de efectuar el cálculo de demanda, requerirá básicamente, el pronóstico y la demanda real del periodo anterior y la constante de suavización, según señala la Figura 18.

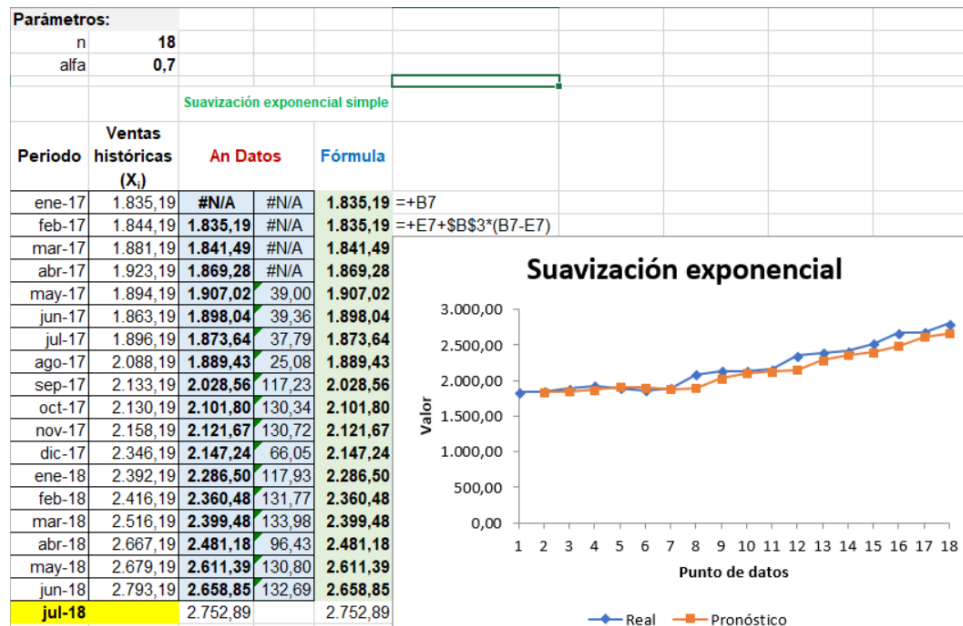


Figura 18: Datos de ventas Empresa Textil

## FASE 2: EVALUACIÓN DE DEPENDENCIAS

Se toma en cuenta que, de cara a la realización de una predicción, no todos los factores tienen la misma repercusión en la ecuación final.

Igual de lógico, y también igual de relevante, es entender que no basta con analizar los resultados históricos del mismo hecho, sino que es imprescindible analizar también todas aquellas nuevas variables que puedan influir sobre el resultado de éste.

Las Direcciones de Planificación también consideran las siguientes variables:

- **La temperatura del medio ambiente:** que condicionan el uso de ciertas prendas de vestir y, por tanto, el inicio de la temporada de invernal o primaveral.
- **Los descuentos por temporada:** que condicionan la caída de precios de acuerdo a inventario o a posicionamiento en el mercado.
- **Publicidad:** influyen drásticamente en la percepción de los clientes ávidos de comprar productos textiles.



- **Competencia:** Los precios, promociones y publicidad de la competencia inciden significativamente en las ventas de productos elaborados.

### FASE 3: MODELADO

Una vez que se cuenta con los datos históricos, actualizados y homogéneos de aquellas variables que se han determinado que van a influir en nuestra predicción. Se ejecuta el modelado estadístico utilizado.

En función del tipo de datos y del tipo de dependencia funcional entre las variables que se tenga, se aplica la técnica de modelado predictivo definido, por lo tanto, la Figura 19, muestra los pasos realizados

Parámetros:	
n	<b>18</b>
alfa	<b>0,7</b>
Periodo	Ventas históricas (X <sub>t</sub> )
ene-17	1.835,19
feb-17	1.844,19
mar-17	1.881,19
abr-17	1.923,19
may-17	1.894,19
jun-17	1.863,19
jul-17	1.896,19
ago-17	2.088,19
sep-17	2.133,19
oct-17	2.130,19
nov-17	2.158,19
dic-17	2.346,19
ene-18	2.392,19
feb-18	2.416,19
mar-18	2.516,19
abr-18	2.667,19
may-18	2.679,19
jun-18	2.793,19
<b>jul-18</b>	

Figura 19: Datos de ventas y pronóstico – AMETEX

El personal de planificación, coincide en que estos sistemas de gestión de ventas garantizan que, a la hora de realizar un próximo pronóstico, se pueda confiar firmemente en que se obtendrá resultados precisos, reales y relevantes.

## FASE 4: CORRECCIONES

Una vez definido nuestro modelo, es importante ir corrigiéndolo para que mejore progresivamente en el desempeño de la predicción.

Esta corrección se podrá realizar de forma manual, por ejemplo, definiendo nuevas dependencias funcionales.

### Datos obtenidos

La Unidad de Planificación comprueba los resultados y emite un informe de resultados con los siguientes parámetros (ver Figura 20)., los cuales son evaluados por gerencia y remitidos al área de producción.

El resultado obtenido se describe a continuación.

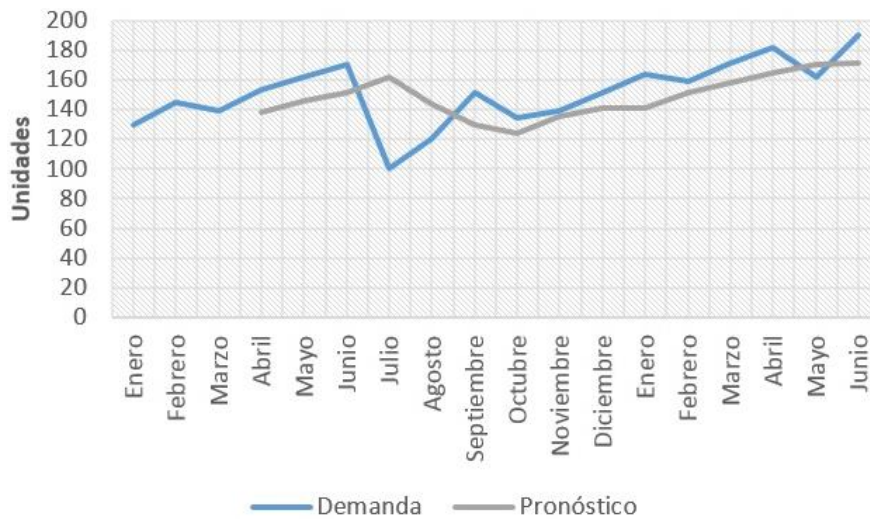


Figura 20: Resultado de demanda de productos.

Fuente: Industria Textil

## CAPÍTULO IV

### MARCO PRÁCTICO

#### 4.1. CONSTRUCCIÓN DE LA RED NEURONAL BASE

La construcción de la red neuronal base, se determinará a partir de los parámetros de entrada y salida de la red que corresponden a las variables influyentes en el pronóstico de la demanda y la cantidad demandada del producto textil, la topología de la red será obtenida mediante procesos de prueba y error para hallar los valores más adecuados del número de capas ocultas, tipo de red, número de neuronas por cada capa.

Se definirán los tipos de productos a pronosticar, las variables de entrada y salida y los valores de cada parámetro de la topología de red más adecuada para resolver el problema.

#### 4.2. DESCRIPCIÓN DE LOS PRODUCTOS

El presente trabajo, pronosticará la demanda de productos producidos y comercializados por las empresas descritas.

Los productos a pronosticar, son los de mayor comercialización, la demanda de estos productos es variada y genera competencia entre una por sobre otra empresa. La denotación y descripción de los productos se menciona a continuación en la Figura 21.

TIPOS DE PRODUCTOS
Productoras de Algodón
Hilanderas
Tejedoras de Tejido Plano
Tejedoras de Tejido de Punto
Confeccionistas Industriales
Confeccionistas Artesanales

Figura 21: Productos textiles  
Fuente: Elaboración propia – Basado en datos INE 2018

### 4.3. DEFINICIÓN DE LAS VARIABLES DE ENTRADA

Para obtener una red que pronostique correctamente se deben elegir cuidadosamente las variables a emplear, de lo que se trata es incluir en el modelo las variables predictoras que realmente pronostiquen la variable dependiente. La introducción de variables irrelevantes puede provocar un sobreajuste innecesario en el modelo [Palmer+05].

Este caso aparece cuando el número de parámetros o pesos de la red resulta excesivo en relación al problema a tratar y al número de patrones de entrenamiento disponible. Teniendo en cuenta lo comentado previamente, se seleccionó un conjunto de variables que permitirán evaluar diferentes aspectos influyentes en el pronóstico de la demanda de productos textiles.

Las variables de entrada son los parámetros que afectan al desempeño de la red que se muestran en la Tabla 10.

Tabla 10: *Definición de variables de entrada del modelo*

Variable	Descripción	Tipo	Codificación
M	Mes	Enero - Diciembre	1-dic
PP	Precio del producto	Bolivianos	Precio en Bs.
P	Promoción	Agresivo	2
		Moderada	1
		No hay	0
TP	Tiempo de la promoción	N.º de días	(1-7) días
PU	Publicidad	Si hubo	1
		No hay	0
PPC	Precio del producto competencia	Bolivianos	Precio en Bs.
PC	Promoción del producto competencia	Agresivo	2
		Moderada	1
		No hay	0
TPC	Tiempo de la promoción del producto competencia	N.º de días	(1-7) días
PUC	Publicidad del producto competencia	Si hubo	1
		No hay	0

Fuente: Elaboración propia.

#### **4.4. DEFINICIÓN DE LAS VARIABLES DE SALIDA**

El propósito es pronosticar la cantidad demandada de un determinado producto textil de manera mensual, por lo cual nuestro problema consta de variables de salida equivalentes a la cantidad de productos textiles que se venderá en dicho mes.

La variable de salida es la cantidad demandada en un respectivo mes del producto elegido, es así que la cantidad hallada representa el total de artículos que se deberá producir.

$$Y_i = \text{Cantidad Pronosticada del Producto } i$$

Se tiene un número suficiente de productos textiles de los cuales se desea hallar sus respectivas demandas, se mostrará los pasos para pronosticar cada de una de ellas, aunque los pasos serán más detallados para el primer producto puesto que la forma de hallar el pronóstico de la demanda de los dos productos restantes es de manera similar.

Para el estudio, se tendrá una salida por cada red neuronal implementada, cada una corresponde a los productos referenciados en la Figura 21.

#### **4.5. TOPOLOGÍA DE LA RED**

El tipo de red neuronal que se va a utilizar es un *perceptrón multicapa*, el diseño que se muestra en la Figura 22, está elaborado en la biblioteca TensorFlow.

La red neuronal consta de cinco capas (1 de entrada, 3 ocultas y 1 de salida), la capa de entrada está compuesta por 9 neuronas que representa la cantidad de variables de entrada, las 3 capas ocultas constan de 5 neuronas y la capa de salida con una neurona, que representa el resultado del sistema.

Esta configuración ha sido obtenida mediante las pruebas realizadas tal y como se muestra en el Anexo 3. La Figura 22 muestra el diseño de la red.




Figura 22: Esquema del diseño de la red neuronal

Fuente: khepri [2018]

La topología de la red propuesta posee las siguientes características:

- *Tipo de red:* Red multicapa unidireccional o perceptrón multicapa (MPL), es decir una red con conexiones que pasan las salidas en una única dirección a neuronas de la siguiente capa.
- *Número de neuronas en la capa de entrada:* 9, valor considerado de acuerdo a las variables de entrada determinadas.
- *Número de capas ocultas:* 3, valor determinado por prueba y error.
- *Número de neuronas en la capa oculta:* 5, valor hallado mediante las pruebas en el entrenamiento de la red que se mostrarán posteriormente en la tesis.
- *Número de neuronas en la capa de Salida:* 1, valor establecido de acuerdo a las variables de salida explicadas.
- *Algoritmo de aprendizaje y validación:* Retropropagación o Backpropagation.

En la Figura 23 se representa el modelo de perceptrón multicapa que se utilizará para el pronóstico de los productos descritos en la Tabla 10. donde se muestran las variables de entrada (M, PP, P, TP, PU, PPC, PC, TPC, PUC) descritos en la Tabla 10, el número de capas ocultas y la cantidad neuronas por cada capa oculta descritos anteriormente y la salida  $\mathbf{Y}$  que representa la cantidad demandada del producto textil pronosticada por la red neuronal que corresponde a la variable  $Y_i$  (variable de salida) que es la cantidad pronosticada del producto  $i$ , con  $i=1,2,3$ .

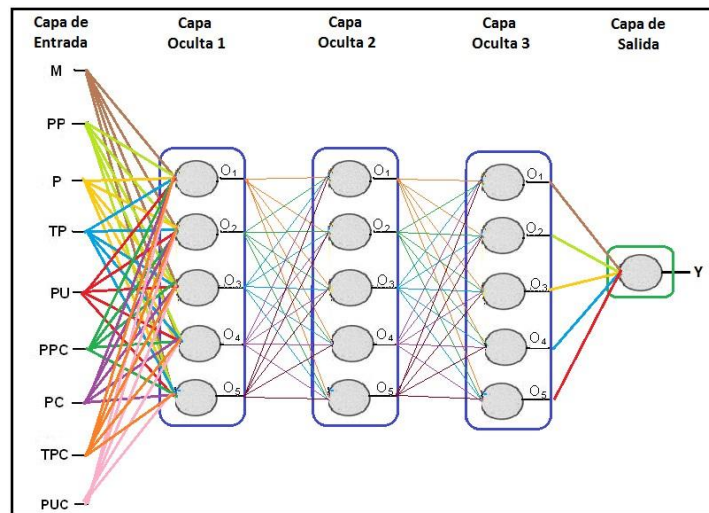


Figura 23: Arquitectura de la red neuronal para cada producto.

Fuente: Walter Pitts (1943)

## 4.6. HERRAMIENTA DE APLICACIÓN

Se mostrarán los requerimientos mínimos de hardware y software para su correcto funcionamiento, la recopilación de los datos históricos para obtener la información sobre las variables de entrada, las instancias de prueba, la validación de la red más adecuada y la implementación de la máscara del software realizado con la biblioteca de código abierto TensorFlow.

## 4.7. CONFIGURACIÓN

### 4.7.1. REQUERIMIENTOS DE HARDWARE Y SOFTWARE

- **Hardware Usado:** Se utilizó una computadora de 1 GB de Memoria RAM, 2.8 GHz de Procesador y 250 GB de disco duro.
- **Software Usado:** Herramienta TensorFlow 2.0 r2.0 (stable), entorno Java (IDE NetBeans 6.5), jdk 6.0, Librería JmatLink 3.0 (jMatLink.dll).
- **Sistema Operativo:** Linux Debian versión 9.

#### 4.7.2. REQUERIMIENTOS MÍNIMOS DE HARDWARE Y SOFTWARE PARA FUNCIONAMIENTO

- **Hardware:** Computadora de 256 de Memoria RAM, 1.6 GHz de Procesador, 20 GB de disco duro.
- **Software:** Herramienta TensorFlow 2.0 r2.0 (stable) , entorno Java (IDE Netbeans 6.5), jdk 5.0, Librería JmatLink 3.0 (jMatLink.dll).
- **Sistema Operativo:** Linux Debian versión 9.

#### 4.8. INSTANCIAS DE PRUEBAS

La Tabla 11 muestra los datos obtenidos concernientes a las variables mencionadas en la Tabla 10 correspondientes al producto de Algodón para cada mes de los años 2014, 2015, 2016, 2017 y el primer trimestre del año 2018 brindados por la empresa textil, de este conjunto seleccionamos los datos de los años 2014, 2015, 2016 y el primer trimestre del año 2017 para la fase de entrenamiento y para la fase de validación de los meses restantes del año 2017 y del primer trimestre del 2018.

La variable PP que corresponde al precio es por cada caja del Producto (unidades con las que opera la empresa) que ha sido obtenido a partir de los registros históricos de la empresa, el resto de variables de entrada han sido estimadas por personal abocado a la planificación, encargado de la actividad de pronóstico, dichas variables juegan un papel importante para la variación de la demanda por lo que su experiencia ha sido útil en la obtención de la data histórica de las variables restantes.



Tabla 11: Datos totales para el entrenamiento y validación

PRODUCTO DE ALGODÓN										
	Mes	Precio producto	Descuento	Tipo de descuento	Publicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Publicidad de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	2	53,83	2	4	1	30,82	0	0	0	6,143
2	2	54,8	0	0	0	32,51	0	0	0	5,857
3	3	55,17	1	7	1	35,26	1	1	0	6,084
4	4	60,55	0	0	1	30,28	0	0	0	1,79
5	5	58,86	0	0	0	39,15	1	2	1	2,761
6	6	63,32	0	0	0	37,17	0	0	0	3,641
7	7	59,84	0	0	1	41,26	0	0	0	3,886
8	8	6,96	1	3	1	31,02	1	3	1	2,972
9	9	60,41	0	0	0	36,84	0	0	1	3,42
10	10	61,25	0	0	1	30,25	1	4	0	3,184
11	11	60,52	0	0	0	34,12	2	5	1	3,932
12	12	6,48	2	5	0	38,25	0	0	1	3,598
13	1	62,96	1	4	1	40,2	0	0	0	5,059
14	2	63,17	0	0	0	4,86	0	0	0	4,863
15	3	62,33	1	7	1	43,15	0	0	0	6,139
16	4	62,73	0	0	0	39,72	0	0	1	3,644
17	5	62,47	0	0	1	38,17	0	0	1	4,951
18	6	64,83	0	0	0	43,02	2	4	1	2,853
19	7	65,9	0	0	1	42,16	0	0	1	2,025
20	8	65,79	0	0	0	39,96	0	0	0	4,225
21	9	68,95	0	0	0	41,25	2	3	1	1,518
22	10	69,05	0	0	1	43,25	1	6	1	3,266
23	11	80,36	1	5	0	40,12	0	0	0	4,033
24	12	80,6	2	6	1	43,12	0	0	0	3,209
25	1	70,71	0	0	1	41,25	2	3	1	4,8
26	2	68,79	1	4	0	42,14	2	2	1	4,454
27	3	69,77	2	5	0	39,26	0	0	0	4,991
28	4	69,56	1	7	0	42,13	1	3	1	4,077
29	5	69,84	0	0	0	41,25	0	0	0	3,579
30	6	70,27	0	0	1	41,68	1	1	0	3,95
31	7	69,94	0	0	1	39,26	0	0	0	3,544
32	8	70,21	2	2	0	39,17	0	0	0	2,986
33	9	69,96	0	0	0	40,13	0	0	0	3,636
34	10	69,81	0	0	1	38,13	0	0	1	2,73
35	11	70,56	0	0	0	36,48	0	0	1	3,285
36	12	70,15	1	5	0	39,13	0	0	0	3,13
37	1	70,72	1	6	1	42,15	0	0	1	5,52
38	2	70,43	2	6	1	39,15	0	0	0	6,163
39	3	73,18	0	0	0	43,34	2	5	1	2,664
40	4	75,25	0	0	0	40,45	2	6	1	2,885
41	5	74,78	0	0	0	41,09	2	4	1	2,423
42	6	75,75	1	3	1	41,78	1	5	0	3,772
43	7	75,39	1	2	1	41,65	1	6	0	3,534
44	8	75,42	1	2	1	41,46	1	3	1	3,487
45	9	74,88	0	0	0	42,09	1	7	1	2,698
46	10	74,3	0	0	0	42,36	2	5	1	2,52
47	11	75,67	2	2	1	42	1	7	0	3,803
48	12	78,77	1	1	0	42,87	2	7	1	2,012
49	1	79,53	2	5	1	43,78	0	0	0	4,051
50	2	79,26	1	6	1	43,96	0	0	0	4,194
51	3	78,46	2	3	1	44,17	0	0	0	5,135

Año 2014

Año 2015

Año 2016

Año 2017

Año 2018

Fuente: Elaboración propia según datos remitidos

#### 4.9. INSTANCIAS DE PRUEBAS PARA EL ENTRENAMIENTO

Como se mencionó previamente los datos para el entrenamiento de la red neuronal equivalen aproximadamente a la tercera parte del total de datos obtenidos que comprenden los registros de la Tabla 12. Esta cantidad de datos con la que cuenta la muestra (39) es prudente para la realización del entrenamiento de la red puesto que muestra una variedad en los datos que será útil para evitar el sobre ajuste o memorización de los mismos.

Tabla 12: Datos para la fase de entrenamiento

	Mes	Precio producto	Descuento	Tipo de descuento	Públicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Públicidad de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	2	53,83	2	4	1	30,82	0	0	0	6,143
2	2	54,8	0	0	0	32,51	0	0	0	5,857
3	3	55,17	1	7	1	35,26	1	1	0	6,084
4	4	60,55	0	0	1	30,28	0	0	0	1,79
5	5	58,86	0	0	0	39,15	1	2	1	2,761
6	6	63,32	0	0	0	37,17	0	0	0	3,641
7	7	59,84	0	0	1	41,26	0	0	0	3,886
8	8	6,96	1	3	1	31,02	1	3	1	2,972
9	9	60,41	0	0	0	36,84	0	0	1	3,42
10	10	61,25	0	0	1	30,25	1	4	0	3,184
11	11	60,52	0	0	0	34,12	2	5	1	3,932
12	12	6,48	2	5	0	38,25	0	0	1	3,598
13	1	62,96	1	4	1	40,2	0	0	0	5,059
14	2	63,17	0	0	0	4,86	0	0	0	4,863
15	3	62,33	1	7	1	43,15	0	0	0	6,139
16	4	62,73	0	0	0	39,72	0	0	1	3,644
17	5	62,47	0	0	1	38,17	0	0	1	4,951
18	6	64,83	0	0	0	43,02	2	4	1	2,853
19	7	65,9	0	0	1	42,16	0	0	1	2,025
20	8	65,79	0	0	0	39,96	0	0	0	4,225
21	9	68,95	0	0	0	41,25	2	3	1	1,518
22	10	69,05	0	0	1	43,25	1	6	1	3,266
23	11	80,36	1	5	0	40,12	0	0	0	4,033
24	12	80,6	2	6	1	43,12	0	0	0	3,209
25	1	70,71	0	0	1	41,25	2	3	1	4,8
26	2	68,79	1	4	0	42,14	2	2	1	4,454
27	3	69,77	2	5	0	39,26	0	0	0	4,991
28	4	69,56	1	7	0	42,13	1	3	1	4,077
29	5	69,84	0	0	0	41,25	0	0	0	3,579
30	6	70,27	0	0	1	41,68	1	1	0	3,95
31	7	69,94	0	0	1	39,26	0	0	0	3,544
32	8	70,21	2	2	0	39,17	0	0	0	2,986
33	9	69,96	0	0	0	40,13	0	0	0	3,636
34	10	69,81	0	0	1	38,13	0	0	1	2,73
35	11	70,56	0	0	0	36,48	0	0	1	3,285
36	12	70,15	1	5	0	39,13	0	0	0	3,13
37	1	70,72	1	6	1	42,15	0	0	1	5,52
38	2	70,43	2	6	1	39,15	0	0	0	6,163
39	3	73,18	0	0	0	43,34	2	5	1	2,664

Fuente: Elaboración propia según datos remitidos

Año 2014

Año 2015

Año 2016

Año 2017

En la Tabla 12 se muestra los datos que corresponden a la fase de entrenamiento, donde  $i$  es la cantidad de datos de la muestra. A continuación, se describe el detalle de los valores que toma cada variable de entrada para un determinado registro en el tiempo (mensualmente).

Para el conjunto de datos del registro  $i=1$  se tiene:

- $M=1$ , indica que el mes de pronóstico es enero.
  - $PP=53.83$ , indica que el precio del producto fue 53.83 bolivianos (por caja).
- $P=2$ , indica que la promoción fue agresiva.
- $TP=4$ , indica que el tiempo de publicidad fue de 4 días.
- $PU=1$ , indica que hubo publicidad ese mes.
  - $PPC=30.82$ , indica que el precio del producto de la competencia fue 30.82 bolivianos (por caja).
- $PC=0$ , indica que el producto de la competencia no tuvo promoción
- $TPC=0$ , indica que el tiempo de promoción de la competencia fue cero debido a que no tuvo promoción.
- $PUC=0$ ; indica que el producto de la competencia no tuvo publicidad.

#### **4.10. INSTANCIAS DE PRUEBA PARA LA VALIDACIÓN**

Los datos para la fase de validación de la red neuronal equivalen aproximadamente a un cuarto del total de datos obtenidos que comprenden los registros de la Tabla 11.

Esta cantidad de datos con la que cuenta la muestra del registro de Tabla 11, es requerido para la validación de la red puesto que muestra una variedad en los datos los mismos que serán útiles para determinar si la red seleccionada generaliza adecuadamente.

	Mes	Precio producto	Descuento	Tipo de descuento	Publicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Publicidad de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
40	4	75,25	0	0	0	40,45	2	6	1	2,885
41	5	74,78	0	0	0	41,09	2	4	1	2,423
42	6	75,75	1	3	1	41,78	1	5	0	3,772
43	7	75,39	1	2	1	41,65	1	6	0	3,534
44	8	75,42	1	2	1	41,46	1	3	1	3,487
45	9	74,88	0	0	0	42,09	1	7	1	2,698
46	10	74,3	0	0	0	42,36	2	5	1	2,52
47	11	75,67	2	2	1	42	1	7	0	3,803
48	12	78,77	1	1	0	42,87	2	7	1	2,012
49	1	79,53	2	5	1	43,78	0	0	0	4,051
50	2	79,26	1	6	1	43,96	0	0	0	4,194
51	3	78,46	2	3	1	44,17	0	0	0	5,135

Año 2017

Año 2018

Figura 24: Datos para la fase de validación

Fuente: Elaboración propia

En la Figura 24, se muestra los datos correspondientes a la validación, donde i es la cantidad de datos de la muestra y los valores indicados conciernen a las variables de entrada indicadas en la Tabla 10, la explicación de cada variable es similar al ejemplo mostrado en la sección anterior.

#### 4.11. NORMALIZACIÓN DE DATOS

El proceso de normalización es necesario para el trabajo puesto que se desea uniformizar los datos ya que las unidades de cada variable son disímiles (por ejemplo, las unidades de los precios son demasiado altas a comparación de las unidades del resto de variables) y se diferencian de manera notable. Con este proceso de normalización denominado Escalado de variables (Feature Scaling o MinMax Scaler), se pretende obtener valores uniformes de entrada en un rango de 0-1 para que no existan dependencias de ninguna variable para la obtención del resultado ya que cada una de ellas influye en el pronóstico de manera análoga. Este proceso se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de los mismos tal y como se muestra en la siguiente ecuación:

$$X_{normalized} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

$D_n$  = Dato Normalizado

$D_i$  = Dato  $i$  de la variable de entrada

$MD$  = Máximo valor de la variable de entrada

A continuación, se muestran dos normalizaciones para explicar de manera clara este proceso.

- **Normalizando la variable M (Mes)**

$MD=12$ : Representa el mayor valor de la variable  $M$  de los datos de toda la muestra de la Tabla 11.

$D_1=1$ : Representa el valor a normalizar, que corresponde al mes de enero.

$D_n=1/12= 0.08$ : Resultado de la normalización.

El valor normalizado para la variable  $M$  y el dato 1 es 0.08

- **Normalizando la variable PP (Precio del producto)**

$MD=80.60$ : Representa el mayor valor de la variable  $PP$  de los datos de toda la muestra de la Tabla 11.

$D_1=53.83$ : Representa el valor a normalizar.

$D_n=53.83/80.60= 0.67$ : Resultado de la normalización.

El valor normalizado para la variable  $PP$  y el dato 1 es 0.6

La normalización de los datos de entrada se lleva a cabo de forma similar para el resto de variables de los datos de entrenamiento y validación, en la Tabla 13 y Tabla 14 se muestran los resultados del proceso de normalización.

Tabla 13: Datos normalizados para la fase de entrenamiento

i	M <sub>i</sub>	PP <sub>i</sub>	P <sub>i</sub>	TP <sub>i</sub>	PU <sub>i</sub>	PPC <sub>i</sub>	PC <sub>i</sub>	TPC <sub>i</sub>	PUC <sub>i</sub>	Y <sub>i</sub>
1	0,0833	0,6678	1,0	0,5714	1	0,8978	0,0	0,0000	0	0,9968
2	0,1667	0,6799	0,0	0,0000	0	0,7360	0,0	0,0000	0	0,9503
3	0,2500	0,6845	0,5	1,0000	1	0,7983	0,5	0,1429	0	0,9872
4	0,3333	0,7513	0,0	0,0000	1	0,6855	0,0	0,0000	0	0,2904
5	0,4167	0,7302	0,0	0,0000	0	0,8863	0,5	0,2857	1	0,4480
6	0,5000	0,7856	0,0	0,0000	0	0,8415	0,0	0,0000	0	0,5908
7	0,5833	0,7424	0,0	0,0000	1	0,9341	0,0	0,0000	0	0,6305
8	0,6667	0,7563	0,5	0,4286	1	0,7023	0,5	0,4286	1	0,4822
9	0,7500	0,7495	0,0	0,0000	0	0,8341	0,0	0,0000	1	0,5549
10	0,8333	0,7599	0,0	0,0000	1	0,6849	0,5	0,5714	0	0,5166
11	0,9167	0,7508	0,0	0,0000	0	0,7725	1,0	0,7143	1	0,6380
12	1,0000	0,7504	1,0	0,7143	0	0,8660	0,0	0,0000	1	0,5838
13	0,0833	0,7811	0,5	0,5714	1	0,9101	0,0	0,0000	0	0,8209
14	0,1667	0,7837	0,0	0,0000	0	0,9251	0,0	0,0000	0	0,7891
15	0,2500	0,7733	0,5	1,0000	1	0,9769	0,0	0,0000	0	0,9961
16	0,3333	0,7783	0,0	0,0000	0	0,8993	0,0	0,0000	1	0,5913
17	0,4167	0,7751	0,0	0,0000	1	0,8641	0,0	0,0000	1	0,8033
18	0,5000	0,8043	0,0	0,0000	0	0,9739	1,0	0,5714	1	0,4629
19	0,5833	0,8176	0,0	0,0000	1	0,9545	0,0	0,0000	1	0,3286
20	0,6667	0,8162	0,0	0,0000	0	0,9048	0,0	0,0000	0	0,6855
21	0,7500	0,8554	0,0	0,0000	0	0,9339	1,0	0,4286	1	0,2463
22	0,8333	0,8567	0,0	0,0000	1	0,9792	0,5	0,8571	1	0,5299
23	0,9167	0,9970	0,5	0,7143	0	0,9083	0,0	0,0000	0	0,6544
24	1,0000	1,0000	1,0	0,8571	1	0,9762	0,0	0,0000	0	0,5207
25	0,0833	0,8772	0,0	0,0000	1	0,9339	1,0	0,4286	1	0,7788
26	0,1667	0,8534	0,5	0,5714	0	0,9540	1,0	0,2857	1	0,7227
27	0,2500	0,8656	1,0	0,7143	0	0,8887	0,0	0,0000	0	0,8098
28	0,3333	0,8629	0,5	1,0000	0	0,9538	0,5	0,4286	1	0,6615
29	0,4167	0,8664	0,0	0,0000	0	0,9339	0,0	0,0000	0	0,5807
30	0,5000	0,8718	0,0	0,0000	1	0,9436	0,5	0,1429	0	0,6409
31	0,5833	0,8676	0,0	0,0000	1	0,8888	0,0	0,0000	0	0,5750
32	0,6667	0,8710	1,0	0,2857	0	0,8868	0,0	0,0000	0	0,4845
33	0,7500	0,8679	0,0	0,0000	0	0,9084	0,0	0,0000	0	0,5900
34	0,8333	0,8660	0,0	0,0000	1	0,8632	0,0	0,0000	1	0,4430
35	0,9167	0,8754	0,0	0,0000	0	0,8259	0,0	0,0000	1	0,5330
36	1,0000	0,8703	0,5	0,7143	0	0,8858	0,0	0,0000	0	0,5079
37	0,0833	0,8774	0,5	0,8571	1	0,9543	0,0	0,0000	1	0,8957
38	0,1667	0,8738	1,0	0,8571	1	0,8863	0,0	0,0000	0	1,0000
39	0,2500	0,9079	0,0	0,0000	0	0,9812	1,0	0,7143	1	0,4323

Año 2014

Año 2015

Año 2016

Año 2017

Fuente: Elaboración propia

Tabla 14: Datos normalizados para la fase de validación

i	M <sub>i</sub>	PP <sub>i</sub>	P <sub>i</sub>	TP <sub>i</sub>	PU <sub>i</sub>	PPC <sub>i</sub>	PC <sub>i</sub>	TPC <sub>i</sub>	PUC <sub>i</sub>	Y <sub>i</sub>
40	0,3333	0,9336	0,0	0,0000	0	0,9158	1,0	0,8571	1	0,4681
41	0,4167	0,9277	0,0	0,0000	0	0,9303	1,0	0,5714	1	0,3932
42	0,5000	0,9398	0,5	0,4286	1	0,9459	0,5	0,7143	0	0,6120
43	0,5833	0,9353	0,5	0,2857	1	0,9429	0,5	0,8571	0	0,5734
44	0,6667	0,9356	0,5	0,2857	1	0,9386	0,5	0,4286	1	0,5658
45	0,7500	0,9290	0,0	0,0000	0	0,9529	0,5	1,0000	1	0,4378
46	0,8333	0,9218	0,0	0,0000	0	0,9590	1,0	0,7143	1	0,4089
47	0,9167	0,9388	1,0	0,2857	1	0,9509	0,5	1,0000	0	0,6171
48	1,0000	0,9772	0,5	0,1429	0	0,9706	1,0	1,0000	1	0,3265
49	0,0833	0,9867	1,0	0,7143	1	0,9912	0,0	0,0000	0	0,6573
50	0,1667	0,9833	0,5	0,8571	1	0,9952	0,0	0,0000	0	0,6805
51	0,2500	0,9734	1,0	0,4286	1	1,0000	0,0	0,0000	0	0,8332

Año 2017

Año 2018

Fuente: Elaboración propia

#### 4.12. FASE DE ENTRENAMIENTO

La fase de entrenamiento de una red neuronal se utiliza para asociar un patrón de entradas a un patrón de salidas de tal manera que la RNA pueda aprender a pronosticar de forma casi exacta la cantidad demanda de cada producto textil de acuerdo al correcto mapeo y conocimiento almacenado (configuración de pesos y bias).

El proceso de entrenamiento de las redes neuronales se realizó usando las funciones del de la biblioteca de código abierto de TensorFlow (estas funciones se describen detalladamente en el Anexo 2) con las cuales se diseñaron varias configuraciones que constan de distintos algoritmos de aprendizaje, así como variación de parámetros. A continuación, se mostrarán las configuraciones de las redes pronosticadoras para los productos.

#### 4.13. PROCESO DE ENTRENAMIENTO DE LA RNA

##### 4.13.1. CONFIGURACIONES PRIMER PRODUCTO DE LAS TOPOLOGÍAS

A continuación, se mostrarán dos redes que fueron creadas y entrenadas cada cual con distintos parámetros en cada fase y se mostrarán sus respectivos errores, los cuales nos servirán para elegir la red más adecuada para el primer producto. Cada configuración define las funciones utilizadas, los parámetros especificados, el esquema de red obtenido, la configuración de los pesos y el performance alcanzado.

### 4.13.2. CONFIGURACIÓN 1

**PRONOSTICADOR\_1.** Red Neuronal que muestra su configuración en la Figura 25. con los diversos parámetros necesarios para su creación.

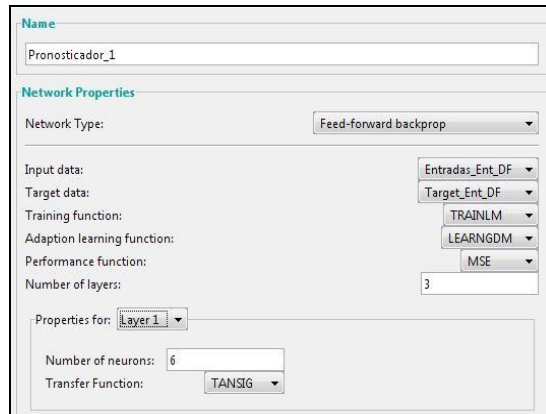


Figura 25: Configuración de la red PRONOSTICADOR\_1

- **Método**

El método utilizado se basa en la creación de una red neuronal backpropagation haciendo uso del entorno de TensorFlow, el cual provee una herramienta para la elaboración de redes neuronales. Esta herramienta cuenta con las funciones específicas para la configuración de cualquier tipo de red.

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1
- Función de Entrenamiento: TRAINLM, función que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt.
- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.



- Numero de capas: 4 (1 de entrada, 2 ocultas y 1 de salida) – Capa de entrada reconocida automáticamente por el MATLAB.
- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 6 neuronas en cada capa oculta y una neurona en la capa de salida. Véase la Figura 26




Figura 26: Esquema de la red neuronal PRONOSTICADOR\_1

Fuente: Elaboración propia.

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 27.

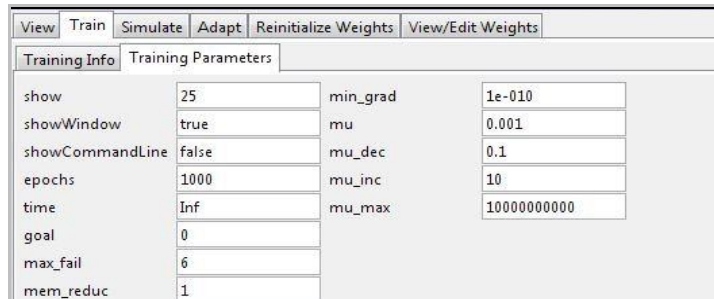


Figura 27: Configuración de los parámetros solicitados por la red

Fuente: Elaboración propia.

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 28.




Figura 28: Configuración de los pesos de la red PRONOSTICADOR\_1

Fuente: Elaboración propia.

- **Resultado**

El resultado que nos muestra el entrenamiento, Figura 29, es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.0872

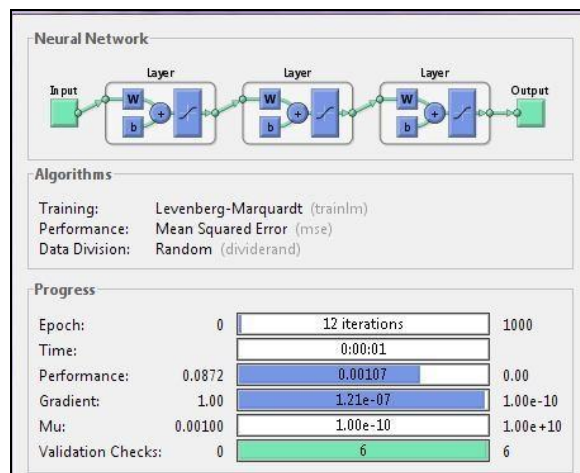


Figura 29: Imagen del entrenamiento realizado por la red PRONOSTICADOR\_1

Fuente: Elaboración propia.

## 4.14. CONFIGURACIÓN 2

**PRONOSTICADOR\_2.** Red Neuronal que muestra su configuración en la Figura 30.

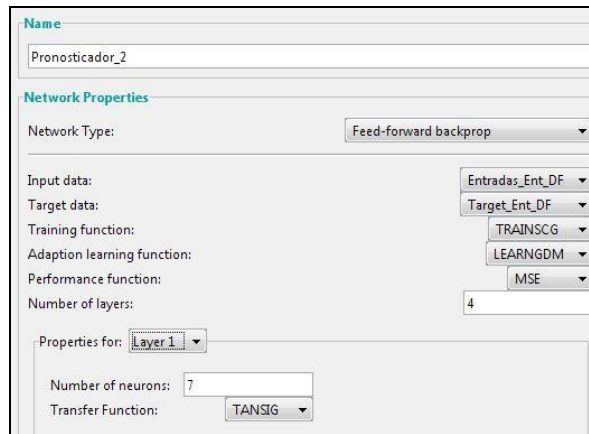


Figura 30: Configuración de la red PRONOSTICADOR\_2

Fuente: Elaboración propia.

- **Método**

RNA backpropagation creado bajo el entorno del NEWRAL NETWORK.

- **Descripción**

La red neuronal creada muestra la siguiente configuración:

- Tipo de red: backpropagation
- Rango de las entradas: 0 y 1

Función de Entrenamiento: TRAINSCG función que actualiza los pesos y valores de los bias de acuerdo al método retropropagación de gradiente conjugado escalado.

- Función de Aprendizaje: LEARNGDM, función de aprendizaje de gradiente descendiente con momentum de los pesos y bias.
- Función de Rendimiento: MSE, Función de rendimiento basado en el error cuadrado medio.
- Numero de capas: 5 (1 de entrada, 3 ocultas y 1 de salida) – Capa de entrada reconocida automáticamente por el TensorFlow.

- Número de neuronas por capa: La primera capa cuenta con 9 neuronas en la capa de entrada, 7 neuronas en cada capa oculta y una neurona en la capa de salida. (ver Figura 31)




Figura 31: Esquema de la red neuronal PRONOSTICADOR\_2

Fuente: Elaboración propia - TensorFlow

- Propiedades de las capas: ambas capas hacen uso de la función Tansig.
- Función de transferencia sigmoidea tangente e hiperbólica.
- Parámetros: Los parámetros de la red se muestran en la Figura 32.

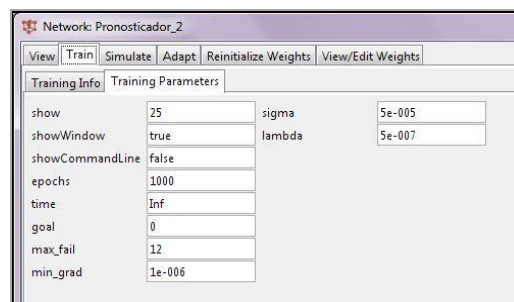


Figura 32: Configuración de los parámetros solicitados por la red

Fuente: Elaboración propia – TensorFlow

- Configuración de pesos: Los pesos hallados de la red se muestra en la Figura 33.

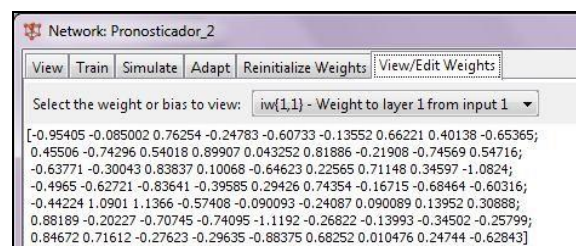


Figura 33: Configuración de los pesos de la red PRONOSTICADOR\_2

Fuente: Elaboración propia - TensorFlow

## Resultado

El resultado que nos muestra el entrenamiento, Figura 34, es el performance o rendimiento que usa la función del error cuadrático medio que es el siguiente:

**Error** → 0.164

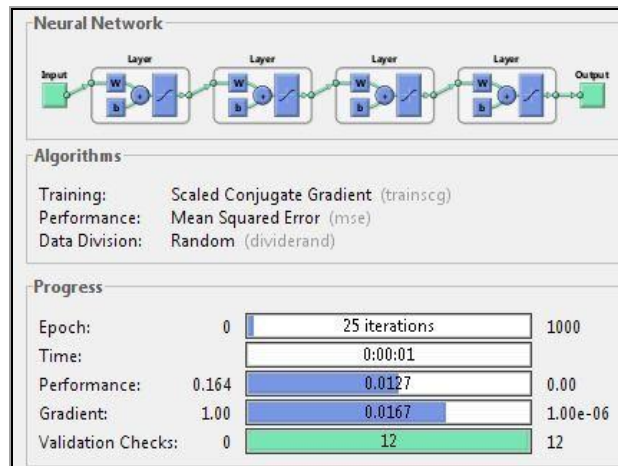


Figura 34: Imagen del entrenamiento realizado por la red PRONOSTICADOR\_2

Fuente: Elaboración propia – TensorFlow

## 4.15. RESUMEN DEL PROCESO DE ENTRENAMIENTO DE LA RNA DEL PRIMER PRODUCTO (ALGODÓN)

En la Tabla 15 se muestra el compendio de los resultados obtenidos en las primeras dos topologías o configuraciones de redes, en este resumen se muestran los datos más importantes empleados (Anexo 4) en el entrenamiento de cada red neuronal que referencian al nombre de la red, al número de neuronas por cada capa oculta (3 primeras columnas de la Tabla 15), luego se muestra el número de épocas realizadas por cada red en su respectivo entrenamiento y el rendimiento o performance equivalente a la función del error cuadrático medio (ECM). Del siguiente cuadro se deduce que las dos configuraciones más adecuadas son: Pronosticador\_3, Pronosticador\_5 y Pronosticador\_8, puesto que estas redes poseen los menores valores correspondientes al ECM.

Tabla 15: Resumen del proceso de entrenamiento de la RN - Algodón

Resultados Obtenidos					
Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
Pronosticador_1	6	6	0	12	0.0872
Pronosticador_2	7	7	7	25	0.1640
<b>Pronosticador_3</b>	<b>6</b>	<b>6</b>	<b>6</b>	<b>6</b>	<b>0.0277</b>
Pronosticador_4	7	7	7	9	0.1010
<b>Pronosticador_5</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>1000</b>	<b>0.0518</b>
Pronosticador_6	7	7	0	2000	0.1070
Pronosticador_7	5	5	0	3000	0.0540
<b>Pronosticador_8</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>1500</b>	<b>0.0300</b>

Fuente: Datos basados en cálculos efectuados (Anexo 3)

#### 4.16. CONFIGURACIÓN ESCOGIDA PARA EL PRIMER PRODUCTO (ALGODÓN)

Las configuraciones escogidas son las redes seleccionadas de acuerdo a la obtención del mejor rendimiento en el resumen del proceso de entrenamiento que se muestra en la Tabla 14 de la sección anterior, estas redes serán empleadas para la fase de validación.

La primera red seleccionada es la red **“Pronosticador\_3”**, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.0277, la segunda es la red **“Pronosticador\_5”** cuyo valor de ECM es 0.0518 y la tercera es la red **“Pronosticador\_8”** que presenta un error de 0.030. Estas 3 redes serán empleadas para la fase de validación donde a partir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del primer producto.

#### 4.17. PROCESO DE ENTRENAMIENTO DE LA RNA DEL SEGUNDO PRODUCTO (HILANDERÍA)

Para el producto Hilandería, se han utilizado las configuraciones presentadas para las redes del producto Algodón. A continuación, sólo se muestran los resultados obtenidos en cada entrenamiento, es decir los ECM (errores cuadráticos medios) Tabla 16.

Tabla 16: Resumen del proceso de entrenamiento de la RNA - Hilandería

Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
Pronosticador_1	6	6	0	12	0.0642
<b>Pronosticador_2</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>39</b>	<b>0.0637</b>
Pronosticador_3	6	6	6	6	0.1150
<b>Pronosticador_4</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>12</b>	<b>0.0534</b>
Pronosticador_5	7	7	7	1000	0.2110
Pronosticador_6	7	7	0	1245	0.0892
<b>Pronosticador_7</b>	<b>5</b>	<b>5</b>	<b>0</b>	<b>3465</b>	<b>0.0285</b>
Pronosticador_8	5	5	5	1500	0.111

Fuente: Datos basados en cálculos efectuados (Anexo 3)

Las configuraciones escogidas son: **“Pronosticador\_7”**, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.02885, la segunda es la red **“Pronosticador\_4”** cuyo ECM es 0.0534 y la tercera es la red **“Pronosticador\_2”** que presenta un error de 0.0637.

Estas 3 redes serán empleadas para la fase de validación donde a partir del ECM que cada una de ellas proyecte seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del producto RG.

#### 4.18. PROCESO DE ENTRENAMIENTO DE LA RNA DEL PRODUCTO TRES (TEJIDO PLANO)

En la siguiente tabla se muestran los resultados obtenidos de las configuraciones de 8 redes neuronales para pronosticar la cantidad demanda del producto Tejido Plano, cada configuración ha sido realizada siguiendo los pasos del proceso de entrenamiento de las RNA producto Tejido Plano. La Tabla 17 detalla cada una de las configuraciones y remarca las 3 redes neuronales más apropiadas para la fase de validación.

Tabla 17: Resumen del proceso de entrenamiento de la RNA - Tejido Plano

Red Neuronal	Capas ocultas			Épocas	ECM
	Capa 1	Capa 2	Capa 3		
<b>Pronosticador_1</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>15</b>	<b>0.00044</b>
<b>Pronosticador_2</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>100</b>	<b>0.00540</b>
<b>Pronosticador_3</b>	<b>7</b>	<b>7</b>	<b>0</b>	<b>1500</b>	<b>0.01258</b>
Pronosticador_4	6	6	0	71	0.01736
Pronosticador_5	7	7	7	1000	0.03621
Pronosticador_6	7	7	0	500	0.05840
Pronosticador_7	5	5	0	36	0.36520
Pronosticador_8	5	5	5	1000	0.20650

Fuente: Datos basados en cálculos efectuados (Anexo 3)

La primera red seleccionada es la red **“Pronosticador\_1”**, pues posee el menor error cuadrático medio entre todas las redes entrenadas cuyo valor es 0.00044, la segunda es la red **“Pronosticador\_2”** cuyo valor de ECM es 0.0054 y la tercera es la red **“Pronosticador\_3”** que presenta un error de 0.01258. Estas 3 redes serán empleadas para la fase de validación donde seleccionaremos la red más adecuada para el pronóstico de la cantidad demanda del producto Tejido Plano.



## 4.19. FASE DE VALIDACIÓN

La fase de validación representa el grado de generalización de la red neuronal, en otras palabras, es la capacidad de la red de dar una respuesta correcta ante patrones que no han sido usadas en su entrenamiento.

### 4.19.1. VALIDACIÓN DE LAS REDES DEL PRIMER PRODUCTO (ALGODÓN)

El proceso de validación de las redes neuronales seleccionadas en la sección 4.13. PRONOSTICADOR\_3, PRONOSTICADOR\_5 y PRONOSTICADOR\_8 se realizó utilizando la interfaz del *neural network (NNTool)* de la caja de herramientas de TensorFlow, cuyo procedimiento, resultado y pruebas se mostrará a continuación.

## 4.20. PROCEDIMIENTO EN TENSORFLOW

Se presentaron a las redes los datos correspondientes a las instancias de validación que se había reservado previamente en la Tabla 14, cada red procesó esta nueva información teniendo en cuenta las relaciones aprendidas en el entrenamiento que guarda (recuerda) en forma de vector de pesos sinápticos. La salida de la red será la cantidad prevista de la demanda del producto Hilandería. Comparando esta predicción con el valor real de la carga podremos contrastar la capacidad predictiva del modelo.

En la Figura 35 se muestra la forma en que se valida la red seleccionada en la etapa anterior, en la pestaña SIMULATE de TensorFlow se cargan las entradas para la validación y las salidas para la misma. En la Figura 36 se muestra el vector de error de validación, es decir, los errores resultantes en esta etapa.




Figura 35: Simulación con los datos de validación para la red PRONOSTICADOR\_8




Figura 36: Errores de la validación PRONOSTICADOR\_8

#### 4.21. TASA DE ERROR

La tasa de error será medida utilizando la fórmula del error cuadrático medio para comprobar que el tipo de red seleccionado es el más adecuado.

$$E_c = \frac{1}{N} \sum_{i=1}^N \|y^i - s^i(w)\|^2$$

Donde:

$E_c$  = Error cuadrático.

$N$  = Número de muestras en la validación.

$Y^i$  = Salida objetivo de la red para la muestra  $i$ .

$S^i(w)$  = salida estimada de la red para la muestra  $i$ .

En nuestro caso el valor de  $N$  es igual a 12 de acuerdo a los datos de la Tabla 14. (instancias para la fase de validación – 9 meses del año 2015 y primer trimestre del año 2018). A continuación, en la Tabla 18 se observan los resultados obtenidos Tabla 18:

Tabla 18: Resumen del proceso de validación – Producto Algodón

Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
Pronosticador_3	6	6	6	<b>0.10500</b>
Pronosticador_5	7	7	7	<b>0.08020</b>
Pronosticador_8	5	5	5	<b>0.01080</b>

Fuente: Elaboración propia

#### 4.22. VALIDACIÓN DE LAS REDES DEL PRODUCTO HILANDERÍA

El proceso de validación es similar al del producto de Algodón. En este caso las redes neuronales seleccionadas en la sección anterior son: **PRONOSTICADOR\_2**, **PRONOSTICADOR\_4** y **PRONOSTICADOR\_7**. Para este producto se ha realizado la validación con 6 registros, de acuerdo a los datos del Anexo 3. (instancias correspondientes a los 3 meses del año 2015 y primer trimestre del año 2015). A continuación, en la Tabla 19 se observan los resultados obtenidos:

Tabla 19: Resumen del proceso de validación – Producto Hilandería.

Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
Pronosticador_2	7	7	7	<b>0.7822</b>
Pronosticador_4	7	7	7	<b>0.0562</b>
<b>Pronosticador_7</b>	<b>5</b>	<b>5</b>	<b>0</b>	<b>0.0236</b>

Fuente: Elaboración propia

#### 4.23. VALIDACIÓN PRODUCTO TEJIDO PLANO

El proceso de validación es similar al del producto DF. En este caso las redes neuronales seleccionadas en la sección anterior son: **PRONOSTICADOR\_1**, **PRONOSTICADOR\_2** y **PRONOSTICADOR\_3**.

Para este producto se ha realizado la validación con 6 registros, de acuerdo a los datos del Anexo 3. (instancias para la fase de validación – primer trimestre del año 2018). A continuación, en la Tabla 20. se observan los resultados obtenidos:

Tabla 20: Resumen del proceso de validación – Producto Tejido Plano

Resultados Obtenidos – Producto CH				
Red Neuronal	Capas Ocultas			ECM
	Capa 1	Capa 2	Capa 3	
Pronosticador_1	7	7	7	0.00221
Pronosticador_2	7	7	7	0.02645
Pronosticador_3	7	7	0	0.01800

Fuente: Elaboración propia

#### 4.24. APLICACIÓN DE PRONÓSTICO

En esta última etapa el software, que será utilizado por el usuario encargado de las previsiones, está implementado con el IDE de JAVA, NetBeans 6.5, J.D.K. 5.0. ya que esta versión provee las herramientas necesarias para la creación de una interfaz gráfica amigable para el usuario.

#### 4.25. CONEXIÓN JAVASCRIPT – TENSORFLOW

La herramienta usada para la creación de la red es TensorFlow y el lenguaje utilizado para la creación de la interfaz gráfica es JavaScript, por lo cual se necesita una librería especial que realizará la conexión entre ambos lenguajes: el *JmatLink*

##### □ JmatLink.

Es una librería que contiene clases predefinidas para ejecutar comandos en TensorFlow desde una aplicación de Java. Cuenta con 3 clases especiales:

- *jmatlink*.
- *corejmatlink*
- *jmatlinkexception*.

Estas 3 clases funcionan de manera agrupada para realizar la conexión entre ambos lenguajes dentro de un paquete llamado “jmatlink” que se coloca dentro de nuestro proyecto. El dll que trae incorporado se coloca en: C:\windows\system32 para que realice las funciones internamente.

#### **4.26. RENDIMIENTO DE LAS RNA FRENTE A MÉTODOS ESTADÍSTICOS**

Todo el trabajo realizado no será de beneficio si la persona encargada de las previsiones realiza pronósticos de ventas más acertados que las redes neuronales propuestas. El objetivo más trascendental es poder pronosticar la cantidad demandada con un margen de error mínimo o menor a la del encargado de planificación.

Para poder demostrar esta presunción presentamos evidencias en la Tabla 21. que demuestran que la red neuronal predice las cantidades demandadas con menor margen de error que la predicción elaborada por las unidades de planificación.

Primero se explica cómo se ha determinado los valores de cada columna que interviene en la comparación de los pronósticos de los productos.

- Cantidad prevista por equipo de planificación: Es la cantidad que el planificador en la empresa calcula se venderá en el mes dado de acuerdo a la siguiente fórmula estadística:

$$CP_i = (CD_{i-1} + CD_{i-2} + CD_{i-3}) / 3$$

Donde:

CP<sub>i</sub> Cantidad Pronosticada del mes i

CD<sub>i-1</sub> Cantidad Demanda Real del mes i-1

CD<sub>i-2</sub> Cantidad Demanda Real del mes i-2

CD<sub>i-3</sub> Cantidad Demanda Real del mes i-3

Para el producto Algodón:

Mes = Agosto 2014 donde i= 8

$$CP = (CD(\text{Julio}) + CD(\text{Junio}) + CD(\text{Mayo}))/3$$

$$CP = (2025 + 2853 + 4951)/3 \quad CP = 3276 \quad \text{cajas de Algodón}$$

Se debe tener en cuenta que, si la cantidad pronosticada se vende antes del término del mes, la empresa vuelve a calcular la cantidad pronosticada para el tiempo restante del mismo mes, en el mes de agosto de 2007 la cantidad demandada real fue de 4225 cajas del producto Algodón, significa que los 3276 se terminó de vender el día 22 de dicho mes.

El encargado de planificación observó que para el día 20 había en stock 50 cajas de Algodón, por lo que la decisión tomada es de comprar más cajas por lo que la cantidad a comprar para cubrir el mes sería.

$$CPri = ((CPi / DM) \times DC) - \text{stock}$$

Donde:

CPri Cantidad Pronosticada para el resto de días del mes i

- DC Cantidad de días por cubrir
- DM Días del mes
- Stock Stock del producto

Prosiguiendo con el ejemplo del mes de agosto del 2018 se tiene:

$$CPri = ((CP(\text{Agosto}) / 31) * 11) - 50$$

$$CPri = ((3276 / 31) * 11) - 50 \quad CPri = 1113 \text{ cajas de Hilandería}$$

Cantidad pronosticada por la RNA: Esta es la cantidad pronosticada por la red neuronal del sistema propuesto, en el cual se le ingresan los valores de entrada y éste determina la cantidad pronosticada para dicho mes.

Demanda real: Esta es la cantidad real de ventas que ha sido proporcionada a la empresa.

Error del encargado: Esta cantidad representa la diferencia entre la cantidad pronosticada por la empresa y la demanda real.

Error de la RNA: Esta cantidad representa la diferencia entre la cantidad pronosticada por la red Neuronal y la demanda real.

En la Tabla 21 se muestra el cuadro comparativo entre las cantidades pronosticadas por el experto encargado de realizar las previsiones en la empresa.

Las cantidades pronosticadas por la red neuronal PRONOSTICADOR\_3 entrenada y validada para el producto Algodón, así mismo se muestran los errores por cada mes de la red neuronal y del experto tomando como referencia los últimos 9 meses del año 2015 y el primero trimestre del 2018 que corresponden a los datos de validación.

Tabla 21: Cuadro comparativo del producto Algodón

(cantidades del planificador vs. cantidades de la RN)

Mes	Cantidad prevista por planificación	Cantidad pronosticada por la RNA	Demanda Real	Error del planificador	Error de la RNA
abr-17	4782	2673	2885	1897	212
may-17	3904	2530	2423	1481	107
jun-17	2657	3789	3772	1115	17
jul-17	3027	3466	3534	507	68
ago-17	3243	3512	3487	244	25
sep-17	3598	2788	2698	900	90
oct-17	3240	2468	2520	720	52
nov-17	2902	3803	3803	901	0
dic-17	3007	2012	2012	995	0
ene-18	2778	3924	4051	1273	127
feb-18	3289	4893	4194	905	699
mar-18	3419	5084	5135	1716	51
<b>TOTAL:</b>	<b>39846</b>	<b>40942</b>	<b>40514</b>	<b>12654</b>	<b>1448</b>

Fuente. Elaboración propia en base a resultados de TensorFlow

De los resultados mostrados se deduce que la red neuronal propuesta obtiene mejores predicciones que el encargado de las previsiones en la empresa puesto que el ECM obtenido por la RN es de 3,57% valor que es mucho menor comparado con el 31,23% del ECM del encargado de planificación.

$$Error(RN)_{DF} < Error(experto)_{ALGODÓN} \rightarrow 3,57\% < 31,23\%$$

## **CAPÍTULO V**

### **CONCLUSIONES Y RECOMENDACIONES**

#### **5.1. CONCLUSIONES**

El presente trabajo reveló la importancia que tiene para las empresas del rubro textil actuales, la correcta previsión de la demanda, pues ella se convierte en una herramienta de gran valor para llevar a cabo una adecuada planificación empresarial, por lo que se consideran las siguientes conclusiones:

Se ha desarrollado un modelo basado en redes neuronales artificiales, gracias a su capacidad de aprender a partir de los ejemplos que se le proporcionan, sin hacer suposiciones a priori sobre los modelos y relaciones que subyacen en la serie, pueden ser aplicadas directamente, lo que facilita considerablemente el proceso de cálculo para pronosticar.

Es factible entrenar una red neuronal artificial perceptrón multicapa a partir de las principales variables que influyen en la demanda, con un desempeño que permite su utilización en el proceso de provisión de aprovisionamiento en empresas textiles.

Los resultados alcanzados confirman la posibilidad de uso de RNA como técnicas confiables de pronóstico y favorecen su implementación en empresa textiles nacionales.

Se desarrolló un software de predicción basado en la técnica de redes neuronales, haciendo uso de una herramienta brindada por TensorFlow (Neural Network), que ofrece la posibilidad de diseñar una red ajustada al desarrollo de nuestro problema.

#### **5.2. RECOMENDACIONES**

Las empresas textiles del sector textil, experimentan una baja considerable de venta de productos, principalmente debido a la competencia de productos importados, por ello se recomienda fortalecer los procesos de verificación de la demanda a objeto de minimizar costos en abastecimiento de materias primas y reducir los costos implícitos.



## REFERENCIA BIBLIOGRÁFICA

1. Fernández Fernández, J. y Flores Lope R. (2008). Las Redes Neuronales Artificiales. España: NETBIBLO, S.L.
2. De la Fuente Aparicio, M y Calonge Cano T. (1999). Aplicaciones de las Redes de Neuronas en Supervisión, Diagnóstico y Control de Procesos. Venezuela: EQUINOCCIO.
3. Muñoz E., Blázquez, J.L., Galparsoro N., González, B. (2011) Estimulación Cognitiva y Rehabilitación Neuropsicológica. Cataluña: Ed. UCO.
4. Minsky, M. y Papert, S. (1987). Perceptrons: An Introduction to Computational Geometry. Massachusetts ; The MIT Press, Vol. 165, Issue 3895, 780-782.
5. Dictionary of Algorithms and Data Structures. (1998). [en línea]. EUA: National Institute of Standards and Technology. Disponible en: [http://\[www.xlinux.nist.gov\]/dads/](http://[www.xlinux.nist.gov]/dads/) [1998, 4 de septiembre].
6. George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, Greta M. Ljung. (2015) Time Series Analysis: Forecasting and Control. San Francisco: Ed. Wiley, 4a. ed.
7. Brown, R.G. (1963) Smoothing, Forecasting and Prediction of Discrete Time Series. New York: Dover Publications.
8. Estrada, B., Priego J. L. (2006). Pronóstico de Precios del Jitomate Saladette Usando un Modelo ARIMA. Tesis para optar al grado de licenciatura: Universidad Autónoma de Chapingo.
9. Marroquín Martínez, G. y Chalita Tovar, L.E. (2011). Aplicación de la metodología Box-Jenkins para Pronóstico de Precios en Jitomate. Revista Mexicana de Ciencias Agrícolas México, 2 (4).
10. Velásquez, J.D, I. Dyner, Souza, R.C. (2006). Modelado del Precio Spot de la Electricidad en Brasil usando una red neuronal autorregresiva. Ingeniare, Revista Chilena de Ingeniería, 16(3), p.394 – 403.
11. Velásquez, J.D. y. Gonzales, L.M. (2006). Modelado del índice de tipo de cambio real colombiano usando redes neuronales artificiales. Cuadernos de Administración, 19 (32), p.1.
12. Zapata, C.M, Giraldo, G.L. (2008). Tendencias en Ingeniería de Software e Inteligencia Artificial, Medellín, Colombia: LitoNueve, pp.67-74.

13. Sánchez, P. y Velásquez, J.D. (2010). Problemas de Investigación en la Predicción de Series de Tiempo con Redes Neuronales Artificiales. *Revista Avances en Sistemas e Informática*, 7(3), pp.67-73.
14. Sánchez, P. y Velásquez, J.D. (2011). El rol del algoritmo de entrenamiento en la selección de modelos de redes neuronales. *Rev. U.D.C.A Act. & Div. Cient*, 1(14), pp.149 - 156.
15. Christopher, M. (1994). *Logística y aprovisionamiento: cómo reducir costes, stocks y mejorar los servicios*. Barcelona: Folio.
16. Chopra, S. y Meindl, P. (2006). *Supply Chain Management*. USA: Pearson/Prentice Hall. 2006.
17. Mentzer, J.T. y Bienstock, C.C. (1998). *Gestión de Previsión de Ventas: Un enfoque de gestión de la demanda*. Tennessee: Sage Publications, Inc; Har / Dis edición.
18. Nojek, S., Britos, P., Rossi y Garcia Martinez, R. (2002). Pronóstico de Ventas: Comparación de Predicción basada en redes neuronales versus método estadístico. *Reportes Técnicos en Ingeniería del Software*. Vol 5(1). Pág. 1-12. 2003.
19. Palmer Pol, A., Montaña Moreno, J.J , Calafat Far, A. (2000). Predicción Del Consumo de Fármacos A Partir De Redes Neuronales Artificiales. *Adicciones revista versión online*, 12 (1).
20. Parisi, A. (2002). Evaluación de Modelos de Redes Neuronales de predicción del signo de la variación del IPSA, *Estudios de Administración*, v.9, n1.
21. Parker, D. (1987), Optimal algorithms for adaptive networks: Second order backpropagation, second order direct propagation and second order Hebbian learning. *IEEE 1st Int. Conf. on Neural Networks*, vol.2, pp.593-600.
22. Petrovic, D., Xie, Y., Burnham, K. (2006). Fuzzy decision support system for demand forecasting with a learning mechanism, *Fuzzy Sets and Systems*. *SciencieDirect*, 157 (12), 1713-1725.
23. Pino, R., Parreño, J., dela Fuente, D., Priore Moreno, P. (2002). Aplicación de Redes Neuronales Artificiales a la Previsión de Series Temporales No estacionarias o no Invertibles. *QUESTIIO*, 26 (3).
24. Viñuela, P.I y Galvan, I.M. (2004). *Redes de Neuronas Artificiales: Un enfoque práctico*. España: Pearson Educación.

25. Vera, M. y Bustamante, J. (2007). Modelo dinámico para la generación de pronóstico usando redes neurales artificiales (RNA). *Visión gerencial*,6, 130-142.
26. Alderete Peralta, A. (2014) Metodología para Implementar Redes Neuronales Artificiales Recurrentes Predictivas. Tesis Licenciatura en Matemáticas Aplicadas y Computación, México, Universidad autónoma de México

## **ANEXO 1: Políticas inherentes al sector textil**

### **BANCO CENTRAL DE BOLIVIA**

Encuentro de Economistas de Bolivia

### **BALANZA COMERCIAL Y POLITICA INDUSTRIAL DEL SECTOR TEXTIL BOLIVIANO PERIDO 2000-2018 CODIGO 10486**

#### **VIII. POLITICAS PUBLICAS IMPLIMENTADAS EN EL SECTOR TEXTIL ACTUAL**

Una política industrial se refiere a la intervención del Estado en la industria para organizar y modificar la estructura y los esquemas de producción.

Las políticas dirigidas al sector textil se encuentran dentro de los programas de desarrollo del Ministerio de Desarrollo y Economía Plural, enfocados a la industria textil y dentro del Plan nacional de Desarrollo que contribuirá a la transformación de la matriz productiva para cambiar el actual patrón primario exportador excluyente. }

#### **V.III.1 COMPLEJOS PRODUCTIVOS**

Para mejorar los niveles de interrelación o cointegración el Ministerio de Desarrollo Productivo y Economía Plural (MDPyEP), ha propuesto en su “Plan sectorial de desarrollo integral para vivir bien, Industria, Manufactura y Artesanía 2016 – 2020”, trabajar con un enfoque de Complejos Productivos de manera integral trascendiendo territorios. Para su operativización, se han priorizado (textiles, endulzantes, hortalizas, madera, insumos para la producción, transformación productos amazónicos, granos, papa, lácteos, cuero, carnes, coca y fruta). Para cada uno de estos complejos se cuenta con un plan de intervención específica con empresas tanto públicas como privadas como agentes estratégicos y dinamizadores.

Estos Complejos Productivos, fueron identificados a través de un “modelo de priorización” en base a los siguientes criterios:

1. Mayor potencial de desarrollo productivo: donde se considera las variables i) volumen de producción; ii) valor agregado; iii) generación de empleo; iv) capacidad de distribución

(número de unidades productivas); v) volumen de ventas internas; vi) transformación de materias primas nacionales.

2. Encadenamientos: efectos multiplicadores en otros sectores productivos.
3. Contribución a la seguridad alimentaria con soberanía.
4. Sustitución de Importaciones.

Adicionalmente y de manera sistémica y complementaria se plantea desarrollar a través de la Plataforma Nacional de Innovación y Tecnología; implementar mecanismos para facilitar el acceso a tecnología e innovación productiva para MyPEs, medianas y grandes empresas, a través de Centros de Tecnología e Innovación y Centros de Innovación Productiva 14 a nivel nacional, así como el desarrollo de procesos de investigación e innovación articulados a los complejos productivos priorizados desde empresas, universidades y entidades territoriales.

Para coadyuvar el desarrollo industrial se ha planteado el fortalecer y desarrollar “programas de calificación técnica de los recursos humanos”, a partir de la coordinación entre los diferentes actores que trabajan en la formación técnica, a nivel nacional y territorial en los complejos productivos priorizados; actualmente a través del MDPyEP y el Ministerio de Educación se están desarrollando estándares ocupacionales especializados y en su certificación para el reconocimiento de las habilidades y destrezas adquiridas media nte la experiencia laboral de las MyPEs.

## **VIII.2 FONDO PARA LA REVOLUCIÓN INDUSTRIAL PRODUCTIVA (FINPRO)**

El FINPRO fue creado con recursos del BCB para financiar emprendimientos productivos del Estado que generen excedentes y empleo. Para la constitución del 27 FINPRO, el BCB transfirió \$us 600 millones y concedió un crédito por otros \$us 600 millones (\$us1.200 millones en total) con el fin de otorgar financiamiento a empresas públicas u otras que se conformen con participación mayoritaria del Estado. Los recursos de este fondo, concedidos desde 2013, han sido destinados a proyectos aprobados mediante Decreto Supremo.

### **VIII.3 NUEVA LEY FINANCIERA PARA CRÉDITOS PRODUCTIVOS**

Ley de Servicios Financieros No. 393, promulgada en agosto 2013, señala que el sector productivo se constituye en uno de los sectores con mayor prioridad. El Artículo 94 de dicha Ley, establece que el Estado participará directa y activamente en el diseño e implementación de medidas para mejorar y promover el financiamiento al sector productivo de la economía, a través de las entidades financieras, a fin de lograr una eficiente asignación de recursos para apoyar la transformación productiva, la generación de empleo y la distribución equitativa del ingreso.

En este sentido, los Artículos 66 y 67 mencionan que el Estado definirá niveles mínimos de cartera que las entidades de intermediación financiera estarán obligadas a cumplir, debiendo priorizar la asignación de recursos con destino a vivienda de interés social y al sector productivo principalmente en los segmentos de micro, pequeña y mediana empresa urbana y rural, artesanos y organizaciones económicas comunitarias.

### **VIII.4 POLITICA DE PRODUCCION SELECTIVA**

Priorizarán las actividades que contribuyan a generar valor agregado y diversifiquen la producción nacional Textil, valorándola a partir de crear y posicionar la imagen de país mediante la marca boliviana.

### **VIII.5 POLITICA PARA UN COMERCIO ESTRATÉGICO**

De acuerdo a nuestra problemática de investigación esta política planteada dará solución, según el PND se centra en aprovechar el dinamismo de la demanda externa y de las potencialidades del mercado interno. Este énfasis significa un cambio del enfoque tradicional que estaba orientado principalmente a las exportaciones.

La política de comercio exterior forma parte de la nueva modalidad de relacionamiento económico internacional, consistente en un patrón exportador diversificado y con mayor valor agregado.

### **V.III.6 POLITICAS DE INNOVACIÓN Y DESARROLLO TECNOLÓGICO**

*Bolivia no es competitiva respecto a salarios, infraestructura e incentivos; sin embargo, el factor más relevante que explica nuestro rezago en competitividad es el factor tecnológico que influye directamente en la productividad.*

*Uno de los factores centrales del cambio del patrón primario exportador consiste en la Industrialización y agregación de valor a los productos. Este proceso incorporará tecnología, tanto en el nivel de equipamiento y manejo de procesos de producción, así como en la inclusión de nuevos y mejores productos para el mercado.*

### **VIII. 7 POLÍTICAS DE EMPLEO**

En el Sector Textil como un factor productivo esencial está el empleo. La política de empleo planteada por el Plan Nacional de Desarrollo pretende en el corto, mediano y largo plazo cambios y soluciones efectivas al desempleo, mediante acciones orientadas a una economía que diversifica Sectores, multiplica actores y genera condiciones para la ampliación significativa y la mejora de fuentes de trabajo, como un escenario óptimo para transformar la matriz productiva.

## ANEXO 2: Herramienta TensorFlow

### Propagación hacia atrás

La propagación hacia atrás o backpropagation es un algoritmo que funciona mediante la determinación de la pérdida (o error) en la salida y luego propagándolo de nuevo hacia atrás en la red. De esta forma los pesos se van actualizando para minimizar el error resultante de cada neurona. Este algoritmo es lo que les permite a las redes neuronales aprender.

Veamos un ejemplo de cómo podemos implementar una red neuronal que pueda aprender por sí sola con la ayuda de TensorFlow.

### Configuración de Perceptron multicapa para reconocer dígitos escritos

En este ejemplo vamos a construir un perceptron multicapa para clasificar dígitos escritos. Antes de pasar a la construcción del modelo, exploremos un poco el conjunto de datos con el que vamos a trabajar en la clasificación.

#### MNIST dataset

MNIST es un simple conjunto de datos para reconocimiento de imágenes por computadora. Se compone de imágenes de dígitos escritos a mano como los siguientes:

Para más información sobre el dataset pueden visitar el siguiente enlace, en donde hacen un análisis detallado del mismo.

In [12]:

```
# importando el dataset
from tensorflow.examples.tutorials.mnist import input_data
mnist = input_data.read_data_sets("MNIST_data/", one_hot=True)
Successfully downloaded train-images-idx3-ubyte.gz 9912422 bytes.
Extracting MNIST_data/train-images-idx3-ubyte.gz
Successfully downloaded train-labels-idx1-ubyte.gz 28881 bytes.
Extracting MNIST_data/train-labels-idx1-ubyte.gz
Successfully downloaded t10k-images-idx3-ubyte.gz 1648877 bytes.
Extracting MNIST_data/t10k-images-idx3-ubyte.gz
Successfully downloaded t10k-labels-idx1-ubyte.gz 4542 bytes.
Extracting MNIST_data/t10k-labels-idx1-ubyte.gz
Explorando MNIST dataset
```

In [13]:



```
# forma del dataset 55000 imagenes
```

```
mnist.train.images.shape
```

```
Out[13]:
```

```
(55000, 784)
```

```
In [14]:
```

```
# cada imagen es un array de 28x28 con cada pixel
```

```
# definido como escala de grises.
```

```
digito1 = mnist.train.images[0].reshape((28, 28))
```

```
In [15]:
```

```
# visualizando el primer digito
```

```
plt.imshow(digito1, cmap = cm.Greys)
```

```
plt.show()
```

```
In [16]:
```

```
# valor correcto
```

```
mnist.train.labels[0].nonzero()[0][0]
```

```
Out[16]:
```

```
7
```

```
In [17]:
```

```
# visualizando imagenes de 5 en 5
```

```
def visualizar_imagenes(dataset, cant_img):
```

```
    img_linea = 5
```

```
    lineas = int(cant_img / img_linea)
```

```
    imagenes = []
```

```
    for i in range(lineas):
```

```
        datos = []
```

```
        for img in dataset[img_linea*i:img_linea*(i+1)]:
```

```
            datos.append(img.reshape((28,28)))
```

```
            imgs = np.hstack(datos)
```

```
            imagenes.append(imgs)
```

```
    data = np.vstack(imagenes)
```

```
    plt.imshow(data, cmap = cm.Greys )
```

```
    plt.show()
```

```
In [18]:
```

```
# visualizando los primeros 30 dígitos
```

```
plt.figure(figsize=(8, 8))
```

```
visualizar_imagenes(mnist.train.images, 30)
```

## Construyendo el perceptrón multicapa

Ahora que ya conocemos los datos con los que vamos a trabajar, ya estamos en condiciones de construir el modelo. Vamos a construir un peceptron multicapa que es una de las redes neuronales más simples. El modelo va a tener dos capas ocultas, que se van a activar con la función de

activación ReLU y vamos a optimizar los pesos reduciendo la entropía cruzada utilizando el algoritmo Adam que es un método para optimización estocástica.

In [19]:

```
# Parametros
tasa_aprendizaje = 0.001
epocas = 15
lote = 100
display_step = 1
logs_path = "/tmp/tensorflow_logs/perceptron"

# Parametros de la red
n_oculta_1 = 256 # 1ra capa de atributos
n_oculta_2 = 256 # 2ra capa de atributos
n_entradas = 784 # datos de MNIST(forma img: 28*28)
n_clases = 10 # Total de clases a clasificar (0-9 digitos)

# input para los grafos
x = tf.placeholder("float", [None, n_entradas], name='DatosEntrada')
y = tf.placeholder("float", [None, n_clases], name='Clases')
```

In [20]:

```
# Creamos el modelo
def perceptron_multicapa(x, pesos, sesgo):
    # Función de activación de la capa escondida
    capa_1 = tf.add(tf.matmul(x, pesos['h1']), sesgo['b1'])
    # activacion relu
    capa_1 = tf.nn.relu(capa_1)
    # Función de activación de la capa escondida
    capa_2 = tf.add(tf.matmul(capa_1, pesos['h2']), sesgo['b2'])
    # activación relu
    capa_2 = tf.nn.relu(capa_2)
    # Salida con activación lineal
    salida = tf.matmul(capa_2, pesos['out']) + sesgo['out']
    return salida
```

In [21]:

```
# Definimos los pesos y sesgo de cada capa.
pesos = {
    'h1': tf.Variable(tf.random_normal([n_entradas, n_oculta_1])),
    'h2': tf.Variable(tf.random_normal([n_oculta_1, n_oculta_2])),
    'out': tf.Variable(tf.random_normal([n_oculta_2, n_clases]))
}
```

```

sesgo = {
    'b1': tf.Variable(tf.random_normal([n_oculta_1])),
    'b2': tf.Variable(tf.random_normal([n_oculta_2])),
    'out': tf.Variable(tf.random_normal([n_clases]))
}

with tf.name_scope('Modelo'):
    # Construimos el modelo
    pred = perceptron_multicapa(x, pesos, sesgo)

with tf.name_scope('Costo'):
    # Definimos la funcion de costo
    costo = tf.reduce_mean(tf.nn.softmax_cross_entropy_with_logits(pred, y))

with tf.name_scope('optimizador'):
    # Algoritmo de optimización
    optimizar = tf.train.AdamOptimizer(
        learning_rate=tasa_aprendizaje).minimize(costo)

with tf.name_scope('Precision'):
    # Evaluar el modelo
    pred_correcta = tf.equal(tf.argmax(pred, 1), tf.argmax(y, 1))
    # Calcular la precisión
    Precision = tf.reduce_mean(tf.cast(pred_correcta, "float"))

# Inicializamos todas las variables
init = tf.initialize_all_variables()

# Crear sumariación para controlar el costo
tf.scalar_summary("Costo", costo)
# Crear sumariación para controlar la precisión
tf.scalar_summary("Precision", Precision)
# Juntar los resúmenes en una sola operación
merged_summary_op = tf.merge_all_summaries()
In [22]:
# Lanzamos la sesión
with tf.Session() as sess:
    sess.run(init)

# op to write logs to Tensorboard

```

```

summary_writer = tf.train.SummaryWriter(
    logs_path, graph=tf.get_default_graph())

# Entrenamiento
for epoca in range(epocas):
    avg_cost = 0.
    lote_total = int(mnist.train.num_examples/lote)

    for i in range(lote_total):
        lote_x, lote_y = mnist.train.next_batch(lote)
        # Optimización por backprop y funcion de costo
        _, c, summary = sess.run([optimizar, costo, merged_summary_op],
            feed_dict={x: lote_x, y: lote_y})
        # escribir logs en cada iteracion
        summary_writer.add_summary(summary, epoca * lote_total + i)
        # perdida promedio
        avg_cost += c / lote_total
    # imprimir información de entrenamiento
    if epoca % display_step == 0:
        print("Iteración: {0: 04d} costo = {1:.9f}".format(epoca+1,
            avg_cost))

print("Optimización Terminada!\n")

print("Precisión: {0:.2f}".format(Precision.eval({x: mnist.test.images,
    y: mnist.test.labels})))

print("Ejecutar el comando:\n",
    "--> tensorboard --logdir=/tmp/tensorflow_logs ",
    "\nLuego abrir https://0.0.0.0:6006/ en el navegador")

```

```

Iteración: 001 costo = 190.739139247
Iteración: 002 costo = 42.639138275
Iteración: 003 costo = 26.239370855
Iteración: 004 costo = 18.236157751
Iteración: 005 costo = 13.129509245
Iteración: 006 costo = 9.765473726
Iteración: 007 costo = 7.159448563
Iteración: 008 costo = 5.309303818
Iteración: 009 costo = 3.940411947
Iteración: 010 costo = 2.904317733
Iteración: 011 costo = 2.179349244

```

Iteración: 012 costo = 1.597618810  
Iteración: 013 costo = 1.215200688  
Iteración: 014 costo = 0.875238173  
Iteración: 015 costo = 0.760177279  
¡Optimización finalizada!

Precisión: 0.94

Ejecutar el comando:

```
--> tensorboard --logdir=/tmp/tensorflow_logs
```

Luego abrir <https://0.0.0.0:6006/> en el navegador

Como vemos TensorFlow nos da mucha flexibilidad para construir el modelo, modificando muy pocas líneas podríamos cambiar el algoritmo de optimización o el cálculo del error y obtener otros resultados; de esta forma vamos a poder personalizar el modelo para alcanzar mayores niveles de precisión.

## TensorBoard

Otra gran herramienta que nos proporciona TensorFlow es TensorBoard que nos permite visualizar nuestros grafos y nos ayudan a alcanzar un mayor entendimiento del flujo de cálculos que ocurre en nuestro modelo.

Para crear la información de la que se va a nutrir el TensorBoard, podemos definir algunos *scopes* utilizando `tf.name_scope`; también podemos incluir algunos gráficos sumariados con `tf.scalar_summary` y luego llamamos a la función `tf.train.SummaryWriter` dentro de una *Sesión*.

Luego podemos iniciar el *board* con el comando `tensorboard --logdir=logpath` como se puede ver en la salida del último ejemplo.

Los grafos de los casos que se observó vimos, por ejemplo, se ven así.

0.0.0.0:6006/#graphs

Apps Webmin 1.620 on IPython Dashbo JD Edwards Ent Welcome phpMyAdmin Raul E Lopez Bri IT Imported From F Books >> Other bookm

TensorBoard EVENTS IMAGES GRAPHS HISTOGRAMS

Fit to screen  
Download PNG  
Run **perceptron**  
(3)  
Session runs (0)  
Upload Choose File  
Color  Structure  
 Device  
color: same substructure  
gray: unique substructure  
Graph (\* = expandable)  
Namespace\*  
OpNode  
Unconnected series\*  
Connected series\*  
Constant  
Summary  
Dataflow edge  
Control dependency edge  
Reference edge

**Modelo**  
Subgraph: 8  
nodes

Attributes (0)

Inputs (7)

- DatosEntrada
- Variable/read
- Variable\_3/read
- Variable\_1/read
- Variable\_4/read
- Variable\_2/read
- Variable\_5/read

Outputs (3)

- Costo/SoftmaxCrossEntropyWithL
- optimizador
- Precision/ArgMax

Remove from main graph

random\_normal

### **ANEXO 3: Datos históricos de los productos Hilandería y Tejido Plano**

#### **Datos Históricos del producto Hilandería**

El producto Hilandería es el segundo producto que será pronosticado, por lo tanto, a continuación, se darán a conocer los datos a utilizar para su proceso de pronóstico.

- Datos totales: En la siguiente tabla se muestra los datos históricos utilizados para el producto Hilandería, los cuales son 51 y corresponden a 5 años (2014, 2015, 2016, 2017 y el primer trimestre del 2018).

	Mes	Precio producto	Descuento	Tipo de descuento	Publicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Publicidad de producto de competencia	
N°	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	1	9,14	0	0	1	8,35	0	0	1	8,671
2	2	9,99	0	0	1	7,56	0	0	1	6,21
3	3	9,16	1	2	1	7,98	1	1	0	6,635
4	4	9,56	2	5	1	7,75	1	2	0	12,708
5	5	10,72	0	0	1	8,05	1	1	1	8,636
6	6	10,54	2	3	0	8,12	1	4	0	9,122
7	7	9,83	2	4	0	7,98	0	0	1	10,815
8	8	9,7	1	3	1	8,23	1	3	1	10,399
9	9	9,82	0	0	1	7,34	0	0	1	9,865
10	10	9,6	0	0	0	7,34	1	4	0	7,732
11	11	9,72	1	4	1	7,23	2	5	1	9,967
12	12	9,59	0	0	1	7,67	0	0	1	6,167
13	1	9,88	1	4	1	7,95	0	0	0	12,003
14	2	10,01	0	0	0	7,68	2	3	1	4,151
15	3	9,99	0	0	1	7,99	1	2	1	5,346
16	4	9,86	0	0	1	8,07	0	0	1	6,245
17	5	10,87	1	7	1	8,26	0	0	1	15,226
18	6	11,43	2	2	0	8,16	2	1	1	11,475
19	7	11,84	1	2	1	9,31	0	0	1	11,845
20	8	11,8	2	6	1	8,47	0	0	1	16,643
21	9	12,08	0	0	0	9,28	2	3	1	2,901
22	10	12,57	1	1	1	8,72	1	3	1	8,069
23	11	12,07	1	5	0	8,91	0	0	1	11,702
24	12	12,46	0	0	1	8,85	1	2	1	5,421
25	1	12,39	0	0	1	9,51	0	0	1	8,467
26	2	12,43	1	3	0	7,73	2	2	1	7,123
27	3	12,39	2	1	0	8,13	3	5	0	6,236
28	4	12,32	1	1	0	8,92	2	3	1	3,185
29	5	12,51	1	1	1	9,15	0	0	0	7,943
30	6	12,46	0	0	1	8,29	1	1	0	7,721
31	7	12,33	2	2	1	8,95	0	0	1	9,979
32	8	12,24	1	1	0	7,39	0	0	1	9,512
33	9	12,23	0	0	1	7,64	0	0	0	8,726
34	10	12,12	0	0	1	7,53	0	0	1	8,327
35	11	12,45	0	0	1	7,82	1	3	1	6,279
36	12	12,28	1	1	0	7,63	0	0	1	8,242
37	1	13,37	1	2	0	7,9	2	4	0	7,876
38	2	14,27	0	0	1	8,12	1	2	1	6,389
39	3	13,66	1	3	0	7,24	2	6	1	2,09
40	4	14,41	2	1	1	9,15	2	5	0	7,64
41	5	14,48	2	6	1	11,25	0	0	1	11,812
42	6	14,46	0	0	1	9,08	1	3	0	4,768
43	7	15,55	0	0	0	9,37	2	4	0	3,297
44	8	16,15	0	0	1	9,56	1	4	1	4,909
45	9	14,7	1	1	0	9,45	1	3	0	6,031
46	10	14,25	1	2	1	8,99	1	1	1	9,244
47	11	14,46	1	4	1	8,76	0	0	1	9,757
48	12	13,22	0	0	0	8,75	2	6	1	5,817
49	1	15,39	1	3	1	9,03	2	4	0	7,661
50	2	12,82	0	0	1	8,33	1	4	1	6,775
51	3	14,14	1	1	0	8,87	1	4	0	5,646

Datos totales del producto Hilandería



**Datos de entrenamiento:** En la siguiente tabla, se muestra los datos que serán usados para el entrenamiento de la red neuronal, la cual consta de 45 instancias.

	Mes	Precio producto	Descuento	Tipo de descuento	Públicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Públicidad de producto de competencia	
N°	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	1	9,14	0	0	1	8,35	0	0	1	8,671
2	2	9,99	0	0	1	7,56	0	0	1	6,21
3	3	9,16	1	2	1	7,98	1	1	0	6,635
4	4	9,56	2	5	1	7,75	1	2	0	12,708
5	5	10,72	0	0	1	8,05	1	1	1	8,636
6	6	10,54	2	3	0	8,12	1	4	0	9,122
7	7	9,83	2	4	0	7,98	0	0	1	10,815
8	8	9,7	1	3	1	8,23	1	3	1	10,399
9	9	9,82	0	0	1	7,34	0	0	1	9,865
10	10	9,6	0	0	0	7,34	1	4	0	7,732
11	11	9,72	1	4	1	7,23	2	5	1	9,967
12	12	9,59	0	0	1	7,67	0	0	1	6,167
13	1	9,88	1	4	1	7,95	0	0	0	12,003
14	2	10,01	0	0	0	7,68	2	3	1	4,151
15	3	9,99	0	0	1	7,99	1	2	1	5,346
16	4	9,86	0	0	1	8,07	0	0	1	6,245
17	5	10,87	1	7	1	8,26	0	0	1	15,226
18	6	11,43	2	2	0	8,16	2	1	1	11,475
19	7	11,84	1	2	1	9,31	0	0	1	11,845
20	8	11,8	2	6	1	8,47	0	0	1	16,643
21	9	12,08	0	0	0	9,28	2	3	1	2,901
22	10	12,57	1	1	1	8,72	1	3	1	8,069
23	11	12,07	1	5	0	8,91	0	0	1	11,702
24	12	12,46	0	0	1	8,85	1	2	1	5,421
25	1	12,39	0	0	1	9,51	0	0	1	8,467
26	2	12,43	1	3	0	7,73	2	2	1	7,123
27	3	12,39	2	1	0	8,13	3	5	0	6,236
28	4	12,32	1	1	0	8,92	2	3	1	3,185
29	5	12,51	1	1	1	9,15	0	0	0	7,943
30	6	12,46	0	0	1	8,29	1	1	0	7,721
31	7	12,33	2	2	1	8,95	0	0	1	9,979
32	8	12,24	1	1	0	7,39	0	0	1	9,512
33	9	12,23	0	0	1	7,64	0	0	0	8,726
34	10	12,12	0	0	1	7,53	0	0	1	8,327
35	11	12,45	0	0	1	7,82	1	3	1	6,279
36	12	12,28	1	1	0	7,63	0	0	1	8,242
37	1	13,37	1	2	0	7,9	2	4	0	7,876
38	2	14,27	0	0	1	8,12	1	2	1	6,389
39	3	13,66	1	3	0	7,24	2	6	1	2,09
40	4	14,41	2	1	1	9,15	2	5	0	7,64
41	5	14,48	2	6	1	11,25	0	0	1	11,812
42	6	14,46	0	0	1	9,08	1	3	0	4,768
43	7	15,55	0	0	0	9,37	2	4	0	3,297
44	8	16,15	0	0	1	9,56	1	4	1	4,909
45	9	14,7	1	1	0	9,45	1	3	0	6,031

Datos de entrenamiento del producto Hilandería

- **Normalización de datos:** La normalización de datos se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de ellos.

$$D_n = D_i / MD$$

- $D_n$  = Dato Normalizado
- $D_i$  = Dato  $i$  de la variable de entrada.
- $MD$  = Máximo valor de la variable de entrada

De acuerdo a la formula anterior la siguiente tabla muestra los datos de entrenamiento normalizados.

Datos normalizados										
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	0.0833	0.5658	0.0000	0.0000	1.0000	0.7422	0.0000	0.0000	1.0000	0.5210
2	0.1667	0.6184	0.0000	0.0000	1.0000	0.6720	0.0000	0.0000	1.0000	0.3731
3	0.2500	0.5670	0.5000	0.2857	1.0000	0.7093	0.3333	0.1667	0.0000	0.3987
4	0.3333	0.5918	1.0000	0.7143	1.0000	0.6889	0.3333	0.3333	0.0000	0.7636
5	0.4167	0.6636	0.0000	0.0000	1.0000	0.7156	0.3333	0.1667	1.0000	0.5189
6	0.5000	0.6524	1.0000	0.4286	0.0000	0.7218	0.3333	0.6667	0.0000	0.5481
7	0.5833	0.6085	1.0000	0.5714	0.0000	0.7093	0.0000	0.0000	1.0000	0.6498
8	0.6667	0.6005	0.5000	0.4286	1.0000	0.7316	0.3333	0.5000	1.0000	0.6248
9	0.7500	0.6079	0.0000	0.0000	1.0000	0.6524	0.0000	0.0000	1.0000	0.5927
10	0.8333	0.5943	0.0000	0.0000	0.0000	0.6524	0.3333	0.6667	0.0000	0.4646
11	0.9167	0.6017	0.5000	0.5714	1.0000	0.6427	0.6667	0.8333	1.0000	0.5989
12	1.0000	0.5936	0.0000	0.0000	1.0000	0.6818	0.0000	0.0000	1.0000	0.3705
13	0.0833	0.6116	0.5000	0.5714	1.0000	0.7067	0.0000	0.0000	0.0000	0.7212
14	0.1667	0.6196	0.0000	0.0000	0.0000	0.6827	0.6667	0.5000	1.0000	0.2494
15	0.2500	0.6184	0.5000	1.0000	1.0000	0.7102	0.3333	0.3333	1.0000	0.3212
16	0.3333	0.6104	0.0000	0.0000	1.0000	0.7173	0.0000	0.0000	1.0000	0.3752
17	0.4167	0.6729	0.5000	1.0000	1.0000	0.7342	0.0000	0.0000	1.0000	0.9149
18	0.5000	0.7075	1.0000	0.2857	0.0000	0.7253	0.6667	0.1667	1.0000	0.6895
19	0.5833	0.7329	0.5000	0.2857	1.0000	0.8276	0.0000	0.0000	1.0000	0.7117
20	0.6667	0.7304	1.0000	0.8571	1.0000	0.7529	0.0000	0.0000	1.0000	1.0000
21	0.7500	0.7478	0.0000	0.0000	0.0000	0.8249	0.6667	0.5000	1.0000	0.1743
22	0.8333	0.7781	0.5000	0.1429	1.0000	0.7751	0.3333	0.5000	1.0000	0.4848
23	0.9167	0.7472	0.5000	0.7143	0.0000	0.7920	0.0000	0.0000	1.0000	0.7031
24	1.0000	0.7713	0.0000	0.0000	1.0000	0.7867	0.3333	0.3333	1.0000	0.3257
25	0.0833	0.7670	0.0000	0.0000	1.0000	0.8453	0.0000	0.0000	1.0000	0.5087
26	0.1667	0.7694	0.5000	0.4286	0.0000	0.6871	0.6667	0.3333	1.0000	0.4280

Datos normalizados											
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y	
27	0.2500	0.7670	1.0000	0.1429	0.0000	0.7227	1.0000	0.8333	0.0000	0.3747	
28	0.3333	0.7626	0.5000	0.1429	0.0000	0.7929	0.6667	0.5000	1.0000	0.1914	
29	0.4167	0.7744	0.5000	0.1429	1.0000	0.8133	0.0000	0.0000	0.0000	0.4773	
30	0.5000	0.7713	0.0000	0.0000	1.0000	0.7369	0.3333	0.1667	0.0000	0.4639	
31	0.5833	0.7633	1.0000	0.2857	1.0000	0.7956	0.0000	0.0000	1.0000	0.5996	
32	0.6667	0.7577	0.5000	0.1429	0.0000	0.6569	0.0000	0.0000	1.0000	0.5715	
33	0.7500	0.7571	0.0000	0.0000	1.0000	0.6791	0.0000	0.0000	0.0000	0.5243	
34	0.8333	0.7503	0.0000	0.0000	1.0000	0.6693	0.0000	0.0000	1.0000	0.5003	
35	0.9167	0.7707	0.0000	0.0000	1.0000	0.6951	0.3333	0.5000	1.0000	0.3773	
36	1.0000	0.7602	0.5000	0.1429	0.0000	0.6782	0.0000	0.0000	1.0000	0.4952	
37	0.0833	0.8276	0.5000	0.2857	0.0000	0.7022	0.6667	0.6667	0.0000	0.4732	
38	0.1667	0.8833	0.0000	0.0000	1.0000	0.7218	0.3333	0.3333	1.0000	0.3839	
39	0.2500	0.8458	0.5000	0.4286	0.0000	0.6436	0.6667	1.0000	1.0000	0.1256	
40	0.3333	0.8918	1.0000	0.1429	1.0000	0.8133	0.6667	0.8333	0.0000	0.4591	
41	0.4167	0.8963	1.0000	0.8571	1.0000	1.0000	0.0000	0.0000	1.0000	0.7097	
42	0.5000	0.8954	0.0000	0.0000	1.0000	0.8071	0.3333	0.5000	0.0000	0.2865	
43	0.5833	0.9627	0.0000	0.0000	0.0000	0.8329	0.6667	0.6667	0.0000	0.1981	
44	0.6667	1.0000	0.0000	0.0000	1.0000	0.8498	0.3333	0.6667	1.0000	0.2950	
45	0.7500	0.9100	0.5000	0.1429	0.0000	0.8400	0.3333	0.5000	0.0000	0.3624	

Datos de entrenamiento normalizados del producto Hilandería

- **Datos de validación:** En la siguiente tabla, se muestra los datos que serán usados para validación de la red neuronal, la cual consta de 12 instancias.

	Mes	Precio producto	Descuento	Tipo de descuento	Publicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Publicidad de producto de competencia	
N°	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
46	10	14,25	1	2	1	8,99	1	1	1	9,244
47	11	14,46	1	4	1	8,76	0	0	1	9,757
48	12	13,22	0	0	0	8,75	2	6	1	5,817
49	1	15,39	1	3	1	9,03	2	4	0	7,661
50	2	12,82	0	0	1	8,33	1	4	1	6,775
51	3	14,14	1	1	0	8,87	1	4	0	5,646

Datos de validación del producto Hilandería

- **Normalización de Datos:** Los datos serán normalizados con la misma ecuación mostrada en el entrenamiento. Los datos normalizados se muestran en la siguiente tabla

Datos normalizados										
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
46	0.8333	0.8819	0.5000	0.2857	1.0000	0.7991	0.3333	0.1667	1.0000	0.5554
47	0.9167	0.8949	0.5000	0.5714	1.0000	0.7787	0.0000	0.0000	1.0000	0.5863
48	1.0000	0.8181	0.0000	0.0000	0.0000	0.7778	0.6667	1.0000	1.0000	0.3495
49	0.0833	0.9529	0.5000	0.4286	1.0000	0.8027	0.6667	0.6667	0.0000	0.4603
50	0.1667	0.7938	0.0000	0.0000	1.0000	0.7404	0.3333	0.6667	1.0000	0.4071
51	0.2500	0.8751	0.5000	0.1429	0.0000	0.7884	0.3333	0.6667	0.0000	0.3392

Datos de entrenamiento normalizados del producto Hilandería

### Datos históricos del producto Tejido Plano

El producto Tejido Plano es el tercer producto a ser pronosticado, a continuación, se conocerán los datos a utilizar para su proceso de pronóstico.

**Datos totales:** La siguiente tabla muestra los datos históricos utilizados para el producto CH, los cuales son 36 y corresponden a 3 años (2016, 2017 y 2018).

	Mes	Precio producto	Descuento	Tipo de descuento	Pública	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Pública de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	1	5,28	2	4	1	4,51	0	0	1	15,99
2	2	5,24	1	1	1	4,43	0	0	1	13,854
3	3	5,16	1	1	0	4,69	1	1	0	13,835
4	4	5,17	2	7	1	4,92	0	0	1	23,202
5	5	5,14	1	1	0	5,02	1	1	1	12,768
6	6	5,94	0	0	1	5,23	0	0	0	13,543
7	7	5,45	0	0	0	5,11	1	6	0	7,524
8	8	5,13	1	2	1	4,68	1	2	1	14,353
9	9	5,23	1	1	0	4,83	1	1	1	12,195
10	10	6,13	0	0	1	5,18	1	4	0	12,384
11	11	5,14	1	2	0	4,89	2	1	1	14,813
12	12	5,21	1	3	0	5,13	0	0	1	13,888
13	1	5,24	1	4	1	5,15	0	0	1	15,52
14	2	5,25	2	5	0	4,95	1	2	0	19,482
15	3	5,46	1	2	0	5,01	0	0	1	11,082
16	4	5,37	0	0	1	4,59	0	0	0	13,918
17	5	5,44	0	0	1	4,69	0	0	1	14,102
18	6	5,62	1	3	0	4,87	0	0	1	15,776
19	7	5,84	0	0	0	4,91	0	0	1	9,073
20	8	5,88	2	3	1	5,01	0	0	1	17,09
21	9	6,03	0	0	0	5,26	1	5	0	9,092
22	10	6,21	0	0	1	5,31	1	3	0	11,909
23	11	6,09	1	5	0	5,11	0	0	1	15,101
24	12	6,19	1	1	1	4,48	0	0	1	12,73
25	1	6,16	0	0	1	5,46	0	0	0	15,879
26	2	6,19	0	0	0	5,12	0	0	1	13,754
27	3	6,15	0	0	1	5,15	1	1	0	13,468
28	4	6,14	0	0	1	5,19	1	2	0	13,607
29	5	6,2	1	3	0	4,82	1	3	0	13,136
30	6	6,16	0	0	1	4,82	1	1	0	12,788
31	7	6,11	2	2	0	4,91	0	0	1	15,034
32	8	6,1	1	2	0	4,92	1	2	0	14,294
33	9	6,06	0	0	0	5,06	0	0	0	17,707
34	10	6,07	1	2	1	4,49	1	4	1	13,075
35	11	6,12	1	3	0	4,97	0	0	1	16,196
36	12	6,12	1	2	0	4,99	0	0	0	15,477

Datos totales del producto Tejido Plano

**Datos de entrenamiento:** En la siguiente tabla se muestra los datos que serán usados para el entrenamiento de la red neuronal, la cual consta de 30 instancias correspondientes a todos meses de los años 2016 y 2017 y al primer semestre del 2018.

	Mes	Precio producto	Descuento	Tipo de descuento	Pública	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Pública de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	1	5,28	2	4	1	4,51	0	0	1	15,99
2	2	5,24	1	1	1	4,43	0	0	1	13,854
3	3	5,16	1	1	0	4,69	1	1	0	13,835
4	4	5,17	2	7	1	4,92	0	0	1	23,202
5	5	5,14	1	1	0	5,02	1	1	1	12,768
6	6	5,94	0	0	1	5,23	0	0	0	13,543
7	7	5,45	0	0	0	5,11	1	6	0	7,524
8	8	5,13	1	2	1	4,68	1	2	1	14,353
9	9	5,23	1	1	0	4,83	1	1	1	12,195
10	10	6,13	0	0	1	5,18	1	4	0	12,384
11	11	5,14	1	2	0	4,89	2	1	1	14,813
12	12	5,21	1	3	0	5,13	0	0	1	13,888
13	1	5,24	1	4	1	5,15	0	0	1	15,52
14	2	5,25	2	5	0	4,95	1	2	0	19,482
15	3	5,46	1	2	0	5,01	0	0	1	11,082
16	4	5,37	0	0	1	4,59	0	0	0	13,918
17	5	5,44	0	0	1	4,69	0	0	1	14,102
18	6	5,62	1	3	0	4,87	0	0	1	15,776
19	7	5,84	0	0	0	4,91	0	0	1	9,073
20	8	5,88	2	3	1	5,01	0	0	1	17,09
21	9	6,03	0	0	0	5,26	1	5	0	9,092
22	10	6,21	0	0	1	5,31	1	3	0	11,909
23	11	6,09	1	5	0	5,11	0	0	1	15,101
24	12	6,19	1	1	1	4,48	0	0	1	12,73
25	1	6,16	0	0	1	5,46	0	0	0	15,879
26	2	6,19	0	0	0	5,12	0	0	1	13,754
27	3	6,15	0	0	1	5,15	1	1	0	13,468
28	4	6,14	0	0	1	5,19	1	2	0	13,607
29	5	6,2	1	3	0	4,82	1	3	0	13,136
30	6	6,16	0	0	1	4,82	1	1	0	12,788

Datos de entrenamiento del producto Tejido Plano

### Normalización de los datos de entrenamiento

La normalización de datos se ha llevado a cabo a partir de la división de todos los datos de una variable entre el mayor de ellos.

$$D_n = D_i / MD$$

- D<sub>n</sub>= Dato Normalizado
- D<sub>i</sub> = Dato i de la variable de entrada.
- MD=Máximo valor de la variable de entrada

De acuerdo a la formula anterior la siguiente tabla, muestra los datos de entrenamiento normalizados.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
1	0,0833	0,8502	1,0000	0,5714	1,0000	0,8260	0,0000	0,0000	1,0000	0,6892
2	0,1667	0,8438	0,5000	0,1429	1,0000	0,8114	0,0000	0,0000	1,0000	0,5971
3	0,2500	0,8309	0,5000	0,1429	0,0000	0,8590	0,5000	0,1429	0,0000	0,5963
4	0,3333	0,8325	1,0000	1,0000	1,0000	0,9011	0,0000	0,0000	1,0000	1,0000
5	0,4167	0,8277	0,5000	0,1429	0,0000	0,9194	0,5000	0,1429	1,0000	0,5503
6	0,5000	0,9565	0,0000	0,0000	1,0000	0,9579	0,0000	0,0000	0,0000	0,5837
7	0,5833	0,8776	0,0000	0,0000	0,0000	0,9359	0,5000	0,8571	0,0000	0,3243
8	0,6667	0,8261	0,5000	0,2857	1,0000	0,8571	0,5000	0,2857	1,0000	0,6186
9	0,7500	0,8422	0,5000	0,1429	0,0000	0,8846	0,5000	0,1429	1,0000	0,5256
10	0,8333	0,9871	0,0000	0,0000	1,0000	0,9487	0,5000	0,5714	0,0000	0,5337
11	0,9167	0,8277	0,5000	0,2857	0,0000	0,8956	1,0000	0,1429	1,0000	0,6384
12	1,0000	0,8390	0,5000	0,4286	0,0000	0,9396	0,0000	0,0000	1,0000	0,5986
13	0,0833	0,8438	0,5000	0,5714	1,0000	0,9432	0,0000	0,0000	1,0000	0,6689
14	0,1667	0,8454	1,0000	0,7143	0,0000	0,9066	0,5000	0,2857	0,0000	0,8397
15	0,2500	0,8792	0,5000	0,2857	0,0000	0,9176	0,0000	0,0000	1,0000	0,4776
16	0,3333	0,8647	0,0000	0,0000	1,0000	0,8407	0,0000	0,0000	0,0000	0,5999
17	0,4167	0,8760	0,0000	0,0000	1,0000	0,8590	0,0000	0,0000	1,0000	0,6078
18	0,5000	0,9050	0,5000	0,4286	0,0000	0,8919	0,0000	0,0000	1,0000	0,6799
19	0,5833	0,9404	0,0000	0,0000	0,0000	0,8993	0,0000	0,0000	1,0000	0,3910
20	0,6667	0,9469	1,0000	0,4286	1,0000	0,9176	0,0000	0,0000	1,0000	0,7366
21	0,7500	0,9710	0,0000	0,0000	0,0000	0,9634	0,5000	0,7143	0,0000	0,3919
22	0,8333	1,0000	0,0000	0,0000	1,0000	0,9725	0,5000	0,4286	0,0000	0,5133
23	0,9167	0,9807	0,5000	0,7143	0,0000	0,9359	0,0000	0,0000	1,0000	0,6508
24	1,0000	0,9968	0,5000	0,1429	1,0000	0,8205	0,0000	0,0000	1,0000	0,5487
25	0,0833	0,9919	0,0000	0,0000	1,0000	1,0000	0,0000	0,0000	0,0000	0,6844
26	0,1667	0,9968	0,0000	0,0000	0,0000	0,9377	0,0000	0,0000	1,0000	0,5928
27	0,2500	0,9903	0,0000	0,0000	1,0000	0,9432	0,5000	0,1429	0,0000	0,5805
28	0,3333	0,9887	0,0000	0,0000	1,0000	0,9505	0,5000	0,2857	0,0000	0,5865
29	0,4167	0,9984	0,5000	0,4286	0,0000	0,8828	0,5000	0,4286	0,0000	0,5662
30	0,5000	0,9919	0,0000	0,0000	1,0000	0,8828	0,5000	0,1429	0,0000	0,5512

Datos de entrenamiento normalizados del producto Tejido Plano

- **Datos de validación:** En la siguiente tabla se muestra los datos que serán usados para validación de la red neuronal, la cual consta de 6 instancias correspondientes al primer semestre del año 2018.

	Mes	Precio producto	Descuento	Tipo de descuento	Públicidad	Precio producto competencia	Descuento producto de competencia	Tiempo de descuento por promoción	Públicidad de producto de competencia	
i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
31	7	6,11	2	2	0	4,91	0	0	1	15,034
32	8	6,1	1	2	0	4,92	1	2	0	14,294
33	9	6,06	0	0	0	5,06	0	0	0	17,707
34	10	6,07	1	2	1	4,49	1	4	1	13,075
35	11	6,12	1	3	0	4,97	0	0	1	16,196
36	12	6,12	1	2	0	4,99	0	0	0	15,477

Datos de validación del producto Tejido Plano

- **Normalización de los datos de validación:** Los datos serán normalizados con la misma ecuación mostrada en el entrenamiento. Los datos normalizados se muestran en la siguiente tabla.

i	M	PP	P	TP	PU	PPC	PC	TPC	PUC	Y
31	0,5833	0,9839	1,0000	0,2857	0,0000	0,8993	0,0000	0,0000	1,0000	0,6480
32	0,6667	0,9823	0,5000	0,2857	0,0000	0,9011	0,5000	0,2857	0,0000	0,6161
33	0,7500	0,9758	0,0000	0,0000	0,0000	0,9267	0,0000	0,0000	0,0000	0,6770
34	0,8333	0,9775	0,5000	0,2857	1,0000	0,8223	0,5000	0,5714	1,0000	0,5635
35	0,9167	0,9855	0,5000	0,4286	0,0000	0,9103	0,0000	0,0000	1,0000	0,6980
36	1,0000	0,9855	0,5000	0,2857	0,0000	0,9139	0,0000	0,0000	0,0000	0,6671

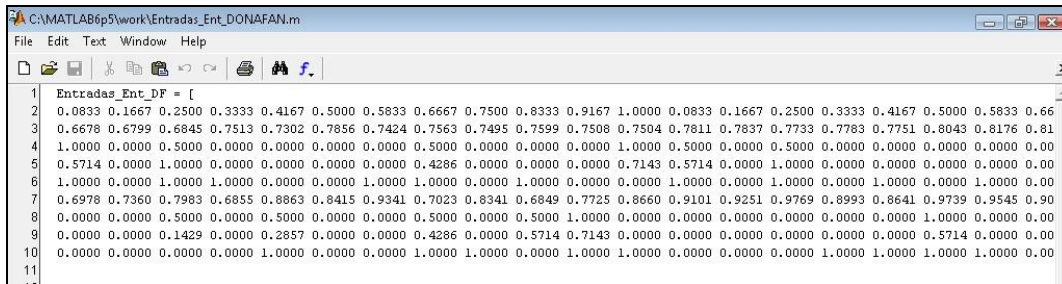
Datos normalizados de validación del producto Tejido Plano



## ANEXO 4: Entrenamiento y validación de la RNA

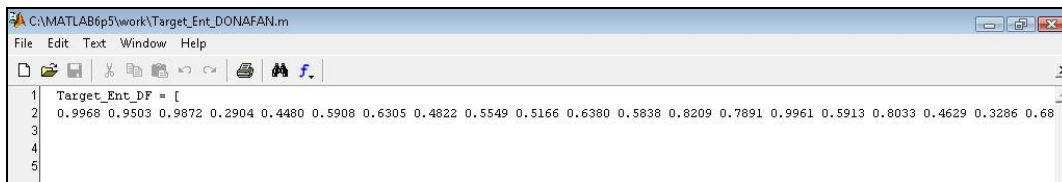
### Archivos .M del producto Algodón

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto Algodón.



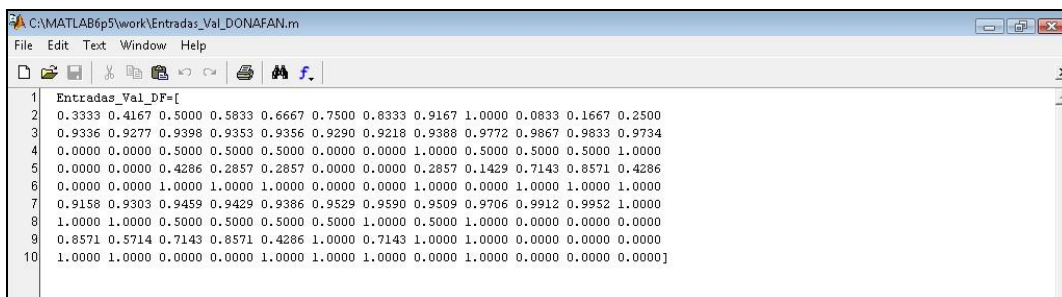
```
1 Entradas_Ent_DF = [  
2 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.66  
3 0.6678 0.6799 0.6845 0.7513 0.7302 0.7856 0.7424 0.7563 0.7495 0.7599 0.7508 0.7504 0.7811 0.7837 0.7733 0.7783 0.7751 0.8043 0.8176 0.81  
4 1.0000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.5000 0.0000 0.0000 0.0000 1.0000 0.5000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.00  
5 0.5714 0.0000 1.0000 0.0000 0.0000 0.0000 0.0000 0.4286 0.0000 0.0000 0.0000 0.7143 0.5714 0.0000 1.0000 0.0000 0.0000 0.0000 0.0000 0.00  
6 1.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.00  
7 0.6978 0.7360 0.7983 0.6855 0.8863 0.8415 0.9341 0.7023 0.8341 0.6849 0.7725 0.8660 0.9101 0.9251 0.9769 0.8993 0.8641 0.9739 0.9545 0.90  
8 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000 0.5000 0.0000 0.5000 1.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.0000 1.0000 0.0000 0.00  
9 0.0000 0.0000 0.1429 0.0000 0.2857 0.0000 0.0000 0.4286 0.0000 0.5714 0.7143 0.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.5714 0.0000 0.00  
10 0.0000 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 0.0000 0.0000 1.0000 1.0000 1.0000 0.00  
11 ]
```

Matriz de entradas para el entrenamiento del producto Algodón Matriz de 9x39



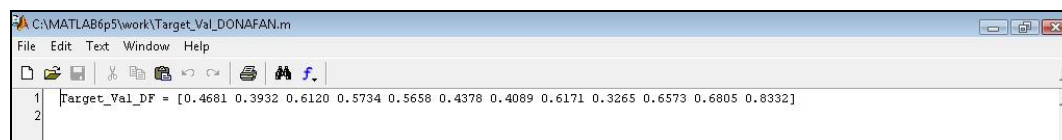
```
1 Target_Ent_DF = [  
2 0.9968 0.9503 0.9872 0.2904 0.4480 0.5908 0.6305 0.4822 0.5549 0.5166 0.6380 0.5838 0.8209 0.7891 0.9961 0.5913 0.8033 0.4629 0.3286 0.68  
3 ]  
4 ]  
5 ]
```

Matriz de salidas(targets) para el entrenamiento del producto Algodón Matriz de 1x 39



```
1 Entradas_Val_DF=[  
2 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500  
3 0.9336 0.9277 0.9398 0.9353 0.9356 0.9290 0.9218 0.9388 0.9772 0.9867 0.9833 0.9734  
4 0.0000 0.0000 0.5000 0.5000 0.5000 0.0000 0.0000 1.0000 0.5000 0.5000 0.5000 1.0000  
5 0.0000 0.0000 0.4286 0.2857 0.2857 0.0000 0.0000 0.2857 0.1429 0.7143 0.8571 0.4286  
6 0.0000 0.0000 1.0000 1.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.0000  
7 0.9158 0.9303 0.9459 0.9429 0.9386 0.9529 0.9590 0.9509 0.9706 0.9912 0.9952 1.0000  
8 1.0000 1.0000 0.5000 0.5000 0.5000 0.5000 1.0000 0.5000 1.0000 0.0000 0.0000 0.0000  
9 0.8571 0.5714 0.7143 0.8571 0.4286 1.0000 0.7143 1.0000 1.0000 0.0000 0.0000 0.0000  
10 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 0.0000 0.0000 0.0000]
```

Matriz de entradas para la validación del producto Algodón Matriz de 9x12



```
1 Target_Val_DF = [0.4681 0.3932 0.6120 0.5734 0.5658 0.4378 0.4089 0.6171 0.3265 0.6573 0.6805 0.8332]  
2 ]
```

Matriz de salidas para la validación del producto Algodón Matriz de 1x12

## Archivos .M del producto Hilandería

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto Hilandería.

```

1 Entradas_Ent_RG=[0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0
2 0.5658 0.6184 0.5670 0.5918 0.6636 0.6524 0.6085 0.6005 0.6079 0.5943 0.6017 0.5936 0.6116 0.6196 0.6184 0.6104 0.6729 0.7075 0.
3 0.0000 0.0000 0.5000 1.0000 0.0000 1.0000 1.0000 0.5000 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 1.0000 0.
4 0.0000 0.0000 0.2857 0.7143 0.0000 0.4286 0.5714 0.4286 0.0000 0.0000 0.5714 0.0000 0.5714 0.0000 1.0000 0.0000 1.0000 0.0000 1.
5 1.0000 1.0000 1.0000 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.
6 0.7422 0.6720 0.7093 0.6889 0.7156 0.7218 0.7093 0.7316 0.6524 0.6524 0.6427 0.6818 0.7067 0.6827 0.7102 0.7173 0.7342 0.7253 0.
7 0.0000 0.0000 0.3333 0.3333 0.3333 0.3333 0.0000 0.3333 0.0000 0.3333 0.6667 0.0000 0.0000 0.6667 0.3333 0.0000 0.0000 0.6667 0.
8 0.0000 0.0000 0.1667 0.3333 0.1667 0.6667 0.0000 0.5000 0.0000 0.6667 0.8333 0.0000 0.0000 0.5000 0.3333 0.0000 0.0000 0.1667 0.
9 1.0000 1.0000 0.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 1.0000 1.0000 1.0000 1.
10
11
    
```

Matriz de entradas para el entrenamiento del producto Hilandería Matriz de 9x45

```

1 Target_Ent = [
2 0.6892 0.5971 0.5963 1.0000 0.5503 0.5837 0.3243 0.6186 0.5256 0.5337 0.6384 0.5986 0.6689 0.8397 0.4776 0.5999 0.6078 0.6799 0.39
3
    
```

Matriz de salidas(targets) para el entrenamiento del producto Hilandería Matriz de 1x 45

```

1 Entradas_Val = [
2 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000
3 0.9839 0.9823 0.9758 0.9775 0.9855 0.9855
4 1.0000 0.5000 0.0000 0.5000 0.5000 0.5000
5 0.2857 0.2857 0.0000 0.2857 0.4286 0.2857
6 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000
7 0.8993 0.9011 0.9267 0.8223 0.9103 0.9139
8 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000
9 0.0000 0.2857 0.0000 0.5714 0.0000 0.0000
10 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000]
11
    
```

Matriz de entradas para la validación del producto Hilandería Matriz de 9x6

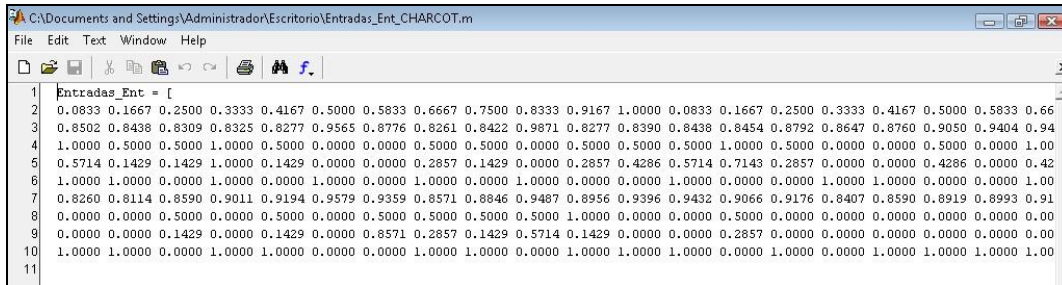
```

1 Target_Val_RG = [0.5554 0.5863 0.3495 0.4603 0.4071 0.3393]
2
    
```

Matriz de salidas para la validación del producto Hilandería Matriz de 1x6

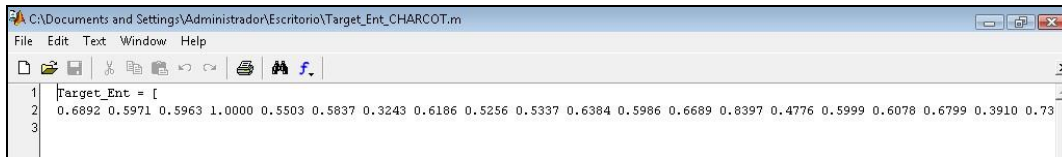
## Archivos .M del producto Tejido Plano

Los siguientes archivos contienen las matrices que serán utilizadas en el Neural Network para el entrenamiento y validación de la Red Neuronal que pronostique la cantidad demandada del producto Tejido Plano.



```
1 Entradas_Ent = [  
2 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000 0.0833 0.1667 0.2500 0.3333 0.4167 0.5000 0.5833 0.66  
3 0.8502 0.8438 0.8309 0.8325 0.8277 0.9565 0.8776 0.8261 0.8422 0.9871 0.8277 0.8390 0.8438 0.8454 0.8792 0.8647 0.8760 0.9050 0.9404 0.94  
4 1.0000 0.5000 0.5000 1.0000 0.5000 0.0000 0.0000 0.5000 0.5000 0.0000 0.5000 0.5000 0.5000 1.0000 0.5000 0.0000 0.0000 0.5000 0.0000 1.00  
5 0.5714 0.1429 0.1429 1.0000 0.1429 0.0000 0.0000 0.2857 0.1429 0.0000 0.2857 0.4286 0.5714 0.7143 0.2857 0.0000 0.0000 0.4286 0.0000 0.42  
6 1.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 1.0000 0.0000 0.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.00  
7 0.8260 0.8114 0.8590 0.9011 0.9194 0.9579 0.9359 0.8571 0.8846 0.9487 0.8956 0.9396 0.9432 0.9066 0.9176 0.8407 0.8590 0.8919 0.8993 0.91  
8 0.0000 0.0000 0.5000 0.0000 0.5000 0.0000 0.5000 0.5000 0.5000 1.0000 0.0000 0.0000 0.5000 0.0000 0.0000 0.0000 0.0000 0.0000 0.0000 0.00  
9 0.0000 0.0000 0.1429 0.0000 0.1429 0.0000 0.8571 0.2857 0.1429 0.5714 0.1429 0.0000 0.0000 0.2857 0.0000 0.0000 0.0000 0.0000 0.0000 0.00  
10 1.0000 1.0000 0.0000 1.0000 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000 1.0000 1.0000 1.0000 0.0000 1.0000 0.0000 1.0000 1.0000 1.0000 1.00  
11 ]
```

Matriz de entradas para el entrenamiento del producto Tejido Plano Matriz de 9x30



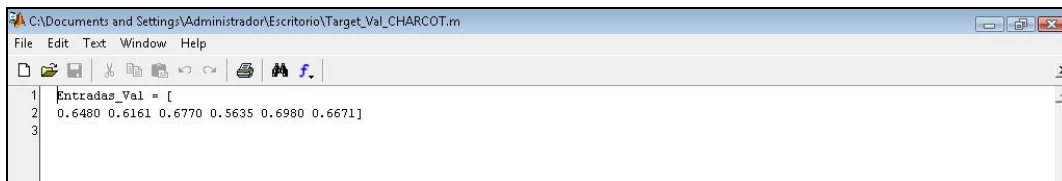
```
1 Target_Ent = [  
2 0.6892 0.5971 0.5963 1.0000 0.5503 0.5837 0.3243 0.6186 0.5256 0.5337 0.6384 0.5986 0.6689 0.8397 0.4776 0.5999 0.6078 0.6799 0.3910 0.73  
3 ]
```

Matriz de salidas(targets) para el entrenamiento del producto Tejido Plano Matriz de 1x 30



```
1 Entradas_Val = [  
2 0.5833 0.6667 0.7500 0.8333 0.9167 1.0000  
3 0.9839 0.9823 0.9758 0.9775 0.9855 0.9855  
4 1.0000 0.5000 0.0000 0.5000 0.5000 0.5000  
5 0.2857 0.2857 0.0000 0.2857 0.4286 0.2857  
6 0.0000 0.0000 0.0000 1.0000 0.0000 0.0000  
7 0.8993 0.9011 0.9267 0.8223 0.9103 0.9139  
8 0.0000 0.5000 0.0000 0.5000 0.0000 0.0000  
9 0.0000 0.2857 0.0000 0.5714 0.0000 0.0000  
10 1.0000 0.0000 0.0000 1.0000 1.0000 0.0000  
11 ]
```

Matriz de entradas para la validación del producto Tejido Plano Matriz de 9x6



```
1 Entradas_Val = [  
2 0.6480 0.6161 0.6770 0.5635 0.6980 0.6671  
3 ]
```

Matriz de salidas para la validación del producto Tejido Plano Matriz de 1x6

## ANEXO 5: Selección de las variables de entrada

### Variables para pronosticar la demanda de productos textiles

Tipo de entrevista para pronosticar la demanda de productos textiles	
1. Datos Personales	
Datos de personal de planificación	Jefe de Planificación
Nombre:	(Denominación)
Objetivo: Obtener las variables actuales con las que cuenta el experto para poder hallar la cantidad de demanda de productos textiles de algodón y poder añadir otras variables que se consideran necesarias según su experiencia.	
Descripción: Se mencionarán variables teóricas que han sido comprobadas mediante estudios técnicos, que influyen directamente en el pronóstico de productos generales y otras variables que se deben seleccionar igualmente puesto que son influyentes en el proceso de pronóstico de productos textiles que son consideradas aptas para tomarse en cuenta.	

Tipos de entrevistas realizadas a personal de planificación.

Fuente. Elaboración propia

Indicar variables que considera actualmente para pronosticar la demanda y agregue variables que influyen en la demanda y actualmente no las consideran.

Entrevista pronóstica de demanda

Variables Consideradas		Observación
Publicidad de productos	<input checked="" type="checkbox"/>	La publicidad del producto es muy determinante para la venta, se transmite por algún medio o por referencias de especialista e incluso de persona que lo han consumido.
Publicidad del bien sustituto	<input checked="" type="checkbox"/>	La publicidad del bien sustituto influye en la demanda de nuestro producto ya que cuando hay mas publicidad del producto competente nuestras ventas disminuyen
Publicidad del bien complementario	<input type="checkbox"/>	
Periodo de pronóstico	<input checked="" type="checkbox"/>	En nuestro caso, la compra de productos farmacéuticos es una vez al mes, y a la vez muchos de ellos dependen de la estación, por tanto el mes es importantes.
Intensidad de la publicidad	<input type="checkbox"/>	

Variables a considerar		Observación
Existencia de la promoción del producto	<input checked="" type="checkbox"/>	Se toma en cuenta en la empresa para predecir el siguiente stock.
Tiempo de la promoción	<input checked="" type="checkbox"/>	También se toma en cuenta
Existencia de la promoción del bien sustituto	<input checked="" type="checkbox"/>	Tenemos en cuenta a la competencia, porque su promoción puede influir en nuestra venta.
Tiempo de la promoción del bien sustituto	<input checked="" type="checkbox"/>	La misma explicación
	<input type="checkbox"/>	

Fuente. Elaboración propia