



Universidad Popular Autónoma del Estado de Puebla

Centro Interdisciplinario de Posgrados

e Investigación

Escuela de Ingeniería

Maestría en Logística y Dirección de la Cadena de Suministro

Pronósticos de la demanda en una industria de muebles.

Tesis que para obtener el Grado de Maestro

En Logística y Dirección de la Cadena de Suministro

Presenta

Natalie Nicole Mar Hernández

Director

Dra. Patricia Cano Olivos

Puebla, México.

Octubre 2019



**UPAEP – Secretaría General**

Dirección General de Apoyos Académicos

Dirección del Centro de Recursos para el Aprendizaje y la Investigación.

Biblioteca Central - **Karol Wojtyła**

**Tesis Digitales Restricciones de uso:**

**DERECHOS RESERVADOS ©**

**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de textos, imágenes, gráficas, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente de donde la obtuvo mencionando el autor o autores involucrados en el documento.

Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



Universidad Popular Autónoma del Estado de Puebla

Vicerrectoría de Posgrados e Investigación

Posgrados en Ingeniería y Negocios

Maestría en Logística y Dirección de la Cadena de Suministro

Se aprueba la Tesis llamada:

Pronósticos de la demanda en una industria de muebles

Comité de Revisión

A handwritten signature in black ink, appearing to be 'Patricia', written over a horizontal line.

Dra. Patricia Cano Olivos  
Director

A handwritten signature in black ink, appearing to be 'Santiago', written over a horizontal line.

Dr. Santiago Omar Caballero Morales  
Asesor

A handwritten signature in black ink, appearing to be 'José Luis', written over a horizontal line.

Dr. José Luis Martínez Flores  
Asesor

Puebla, México.

Octubre 2019



## **RESUMEN**

Esta investigación ofrece una propuesta para la gestión de la demanda en las Pequeñas y medianas empresas (Pymes) de muebles ubicadas en la ciudad de Puebla, México. Se consultaron los datos históricos de producción y se utilizó la metodología de clasificación ABC para conocer los artículos de mayor importancia en la empresa. Posteriormente se analizó la literatura enfocada en las Pymes, como la situación actual e información estadística. Además se presenta una descripción general de los modelos de pronóstico aplicados a las series de tiempo que fueron aplicados a los artículos más relevantes para la empresa. Debido a los resultados y al estudio previo, se decidió implementar una técnica de pronóstico modelada por redes neuronales artificiales (RNA). El modelo RNA fue desarrollado con un algoritmo de backpropagation utilizando el software MATLAB. Las técnicas de pronóstico apropiadas se seleccionaron de acuerdo con la variabilidad de la demanda de los artículos con un horizonte de planificación a corto plazo. Esta investigación ayudará a la compañía a reducir la incertidumbre, pronosticando sus ventas futuras y logrando una mejor planificación de la producción a través de los RNA.

## **ABSTRACT**

This research offers a proposal for demand management in small and medium sized companies (SMEs) of furniture located in the city of Puebla, Mexico. Historical production data were consulted and the ABC classification methodology was used to know the most important articles in the company. Subsequently, the literature focused on SMEs was analyzed, such as the current situation and statistical information. In addition, a general description of the forecast models applied to the time series that were applied to the most relevant articles for the company is presented. Due to the results and the previous study, it was decided to implement a prognostic technique modeled by artificial neural networks (ANN). The ANN model was developed with a backpropagation algorithm using MATLAB software. Appropriate forecasting techniques were selected according to the variability of the demand of the articles with a short-term planning horizon. This research will help the company reduce uncertainty, forecasting its future sales and achieving better production planning through ANNs.

## **AGRADECIMIENTOS**

Gracias a la Universidad Popular Autónoma del Estado de Puebla por haberme aceptado ser parte de ella y abierto sus puertas, expreso mi agradecimiento a mi asesora Dra. Patricia Cano Olivos por brindarme la oportunidad de recurrir a su capacidad y poder experimentar un nuevo nivel de conocimiento, así como también haberme tenido la paciencia para guiarme durante todo este proceso que conllevó mi tesis.

Agradezco a mis compañeros de clase Mariana Jacobo, Karla Rosas y Daniel Luis, por ser buenos compañeros de clase brindándome apoyo en las diferentes circunstancias que nos enfrentamos en cada materia y que sin esperar nada a cambio compartieron su conocimiento, así como también su amistad.

Para finalizar agradezco a mi familia que me brindó su apoyo durante toda mi maestría, gracias por creer en mi capacidad y demostrar su apoyo. No fue sencillo pero siempre estuvo mi familia y amigos motivándome para lograr mi objetivo.

## INDICE GENERAL

RESUMEN .....	3
ABSTRACT.....	3
AGRADECIMIENTOS .....	4
INTRODUCCIÓN .....	6
LITERATURA .....	6
METODOS UTILIZADOS EN LA INVESTIGACION .....	12
METODOLOGIA .....	14
RESULTADOS.....	16
CONCLUSION.....	21
REFERENCIAS.....	21

## INDICE DE TABLAS

Tabla 1. Resultados de la clasificación ABC.....	15
Tabla 2. Daros historicos de la demanda de productos A (2017) .....	15
Tabla 3. Datos historicos de la demanda de productos A (2016).....	15
Tabla 4. Errores de los metodos de pronostico aplicados .....	16
Tabla 5. Demanda pronosticada con método Brown .....	17
Tabla 6. Demanda pronosticada con método Holt.....	17
Tabla 7. Demanda pronosticada Buro con 10 capas y 80 entrenamientos.....	17
Tabla 8. Demanda pronosticada Lámpara con 10 capas y 10 entrenamientos.....	18
Tabla 9. Demanda pronosticada Mesa con 10 capas y 22 entrenamientos .....	18
Tabla 10. Demanda pronosticada Silla con 10 capas y 123 entrenamientos.....	19

## INDICE FIGURAS

Figura 1. Modelo no lineal de una red neuronal .....	10
Figura 2. Red neuronal milticapa con multiples salidas entrenadas .....	11
Figura 3. Comparación grafica de la demanda real y pronosticada para Buro .....	19
Figura 4. Compración grafica de la demanda real y pronosticada para Lámpara .....	20
Figura 5. Comparación grafica de la demanda real y pronosticada para Mesa.....	20
Figura 6. Compración grafica de la demanda real y pronosticada para Silla.....	20

## INTRODUCCIÓN

Actualmente, las pequeñas y medianas empresas (PYME) han enfrentado nuevos desafíos; entonces, las empresas requieren estrategias para la toma de decisiones, lo que permite obtener una ventaja competitiva. La planificación de la demanda es un área estratégica ya que la mayoría de las actividades depende de ella. Por lo tanto, las técnicas de pronóstico son vitales para tomar decisiones a partir de información histórica, lo que permite minimizar los errores y eliminar la incertidumbre en la planificación. Sin embargo, el problema es que la mayoría de las Pymes no lo utilizan, ya sea por su falta de conocimiento o porque no saben cómo elegir la técnica de pronóstico correcta. En México la Pymes representan el 1.15% del producto interno bruto (PIB), emplean a 92, 107 mexicanos (Instituto Nacional de Estadística y Geografía [INEGI], 2018), y según los datos, tienen hasta 250 empleados (Organización para la Cooperación Económica y Desarrollo [OCDE], 2013)

Las PYME deben comenzar a conocer técnicas que les permitan tener una ventaja competitiva. Los métodos de pronóstico han sido una herramienta poderosa que reduce la incertidumbre de sufrir una planificación errónea y, de esta manera, lograr una mejora en el rendimiento de la cadena de suministro. Los pronósticos predicen el futuro en base a los datos históricos y apoyan la toma de decisiones en la organización. Por eso es parte de la administración de la cadena de suministro. Mediante la aplicación de pronósticos tradicionales, se puede observar las limitaciones que afectan la precisión de los mismos. Sin embargo, los algoritmos de redes neuronales artificiales mostraron una mejor respuesta prediciendo la demanda debido a la capacidad de acomodar datos no lineales (Chang & Wang, 2006). “Las técnicas de predicción de inteligencia artificial han recibido mucha atención últimamente para resolver problemas que apenas se resuelven utilizando métodos tradicionales. Los RNA pueden aprender como los humanos, acumulando conocimientos a través de actividades de aprendizaje repetitivas. Proceso de aprendizaje cognitivo del cerebro animal simulado en RNA” (Kumar, Herbert & Rao, 2014).

Esta investigación se aplicó a una empresa mexicana de muebles, la cual es una empresa de tradición familiar y artesanal donde los propietarios administran las operaciones internas y no son especialistas en el área. Esta empresa vende sus productos en diferentes regiones del país, ofreciendo a sus clientes productos para el hogar, el jardín y las oficinas. Por lo tanto, el objetivo principal es aplicar la técnica de pronóstico correcta que estimará la demanda con un error mínimo.

## LITERATURA

Las PYME en la economía actual son de gran importancia debido a la generación de empleo a nivel nacional y regional que generan. En los últimos años, estas empresas se están vinculando con industrias más grandes y proporcionan un equilibrio regional a través de la distribución de inversiones más equitativas (Taiwo, Ayodeji M, & Yusuf A, 2012). Debe considerarse que las condiciones en que operan las Pymes no son precisamente favorables. Su bajo nivel de aceptación tecnológica, trabajadores y / o propietarios insuficientemente calificados, administración ineficiente, baja productividad, entre otros (Zeballos, 2003), minimiza las ventajas competitivas. En México, las Pymes representan alrededor del 4% del total de las unidades económicas, emplean al 32% de la población y producen el 36% del PIB

(Ministerio de economía, 2012). La clasificación de las empresas es de acuerdo con las personas ocupadas y la cantidad de ingresos por año. Los criterios recomendados por la Unión Europea y la OCDE para pequeñas empresas son de 10 a 49 personas y ventas anuales de menos de 10 millones de euros, para empresas medianas son de 50 a 249 personas y transacciones anuales de menos de 50 millones de euros (Instituto Nacional de Estadística y Geografía [INEGI], 2014). Las Pymes son vitales en la red productiva de la región: emplean alrededor del 67% del número total de trabajadores y representan aproximadamente el 99% del número total de empresas. Cabe señalar que la contribución al PIB es relativamente baja en comparación con las grandes empresas (Comisión Económica para América Latina y el Caribe [CEPAL], 2018).

En los últimos años, las Pymes son vitales para el crecimiento económico de un país, lo que fortalece la competitividad y el espíritu empresarial. (Zeballos, 2003), por lo tanto, el gobierno les ha prestado una atención considerable, especialmente en los países del tercer mundo, porque usan más materias primas locales, generan más empleo, fomentan el desarrollo rural y el espíritu empresarial, movilizan ahorros internos, se vinculan a industrias más importantes, proporcionan equilibrio regional a través de la distribución de las inversiones, proporcionan más trabajo por cuenta propia y brindan oportunidades para capacitar a gerentes y trabajadores semicalificados (Taiwo, Ayodeji & Yusuf, 2012). La persona a cargo de la toma de decisiones de una Pyme se enfrenta con desafíos cotidianos. Las habilidades y capacidades para la toma de decisiones que poseen serán la diferencia entre el éxito y el fracaso (Schreier, Udomkit & Macchi, 2016), dentro de las empresas, la decisión siempre se toma a través de dos enfoques, la toma de decisiones racional, que se basa en la teoría y los datos empíricos; y toma de decisiones intuitiva, que se basa en la intuición y datos no racionales (Wiratmadja, Rumanti, Reynaldo & Kurniawati, 2016).

La toma de decisiones juega un papel importante en temas como marketing, desarrollo de recursos humanos, investigación y desarrollo, relaciones públicas e inversión. (Schreier et al., 2016). Estas empresas tienen éxito en los mercados nacionales en términos de crecimiento de la economía y redistribución de los ingresos. Por lo tanto, una de las tareas esenciales para las instituciones del sector público y privado en la región es aprovechar el potencial de estas a nivel local (Zeballos, 2003). Las Pymes, cuando enfrentan varios obstáculos, deben buscar formas de ahorrar dinero o ser más productivas, utilizando herramientas empíricas. La adaptación y la creatividad de las PYME son de gran importancia para permanecer en un entorno globalizado (Soto & Dolan, 2003). Este fenómeno afecta de manera negativa y positiva a todas las empresas, independientemente de su tamaño, giro o ubicación (Lopez, Acosta, Espinoza & Delfín, 2007). Debido a la globalización, las Pymes enfrentan varios desafíos para su desarrollo, que incluyen calidad, flexibilidad, costos, capacitación, entre otros que son de gran importancia para el crecimiento de las empresas. (Gunasekaran, Rai & Griffin 2011).

En la reunión a nivel ministerial del Consejo de la OCDE (2017), Las Pymes se describieron como esenciales para lograr la globalización y el crecimiento actual. Desafortunadamente, algunos países enfrentan el desafío de bajo crecimiento, comercio e inversión débiles, y persistentemente alto riesgo o desigualdad (OCDE, 2017). Debido a esto, es necesario crear condiciones que beneficien a las empresas, dando un beneficio más significativo a la economía y la sociedad. El Banco Interamericano de Desarrollo (BID) (2010) menciona que la apertura del comercio internacional implica la globalización de las cadenas de suministro. Dependiendo de las características, los costos logísticos de las Pymes suelen ser entre dos y tres veces más altos que los de las grandes empresas. Para las Pymes, los costos logísticos son aproximadamente el 40% del valor del producto (BID, 2011), donde los costos logísticos internos pueden ser el 42% de las ventas totales, en comparación con los niveles del 15% al 18% en el caso de grandes empresas (World Trade Organization [WTO], 2016).

El desempeño logístico de la cadena de suministro de las PYMES en México es del 13.3% (Ministerio de Economía, 2011). Rubio (2017) menciona que de 20 organizaciones estudiadas; solo el 55% usa la

técnica de pronóstico y el 45% no la usa. Un pronóstico es una predicción que es una extensión del pasado. Aunque la presencia de cualquier fenómeno aleatorio los hace inciertos, es un proceso en el que se pueden utilizar métodos cuantitativos y cualitativos para realizarlos. El pronóstico es fundamental en la gestión estratégica y es un elemento crucial en un programa de calidad total de cualquier empresa (Alonso & Villegas, 2005). En este sentido, el objetivo principal de la investigación es aplicar métodos de pronóstico para planificar y optimizar los recursos.

Un pronóstico es necesario para las áreas de planificación administrativa; se pronostica lo que ayuda a reducir la incertidumbre. Debido a la variabilidad de la demanda, las pymes toman decisiones intuitivas y la mayoría de las veces desconocen la importancia. Al usar estas técnicas, debe saber cómo y dónde usarlas de una manera que contribuya y sea beneficiosa para la empresa (Hanke & Wichern, 2010). Las previsiones de ventas son esenciales independientemente de la actividad o el tamaño de la empresa. Los pronósticos permiten mejorar el servicio al cliente, reduce los costos y aprovecha las oportunidades que ofrece el mercado para obtener buenos resultados. Se evalúa de forma sistemática y racional, dando una visión futura de la demanda (Morlidge & Player, 2010). Acosta, Diaz & Anaya (2009) mencionan que la aplicación de pronósticos individuales y combinados para 263 series de datos de la misma compañía logra ahorros significativos debido a la predicción correcta. .

La gestión empresarial se ha visto afectada por la volatilidad, pero las Pymes son las más afectadas en comparación con las grandes empresas. La mayoría de las Pymes no utilizan métodos cuantitativos y cualitativos, mientras que las grandes empresas utilizan métodos o software sofisticados. Sin embargo, no tiene una diferencia entre la precisión de los pronósticos (Hofer, Eisl & Mayr, 2015). Las Pymes austriacas suelen utilizar la extrapolación de tendencias a través de diferentes métodos matemáticos. En las grandes empresas, los métodos cualitativos se utilizan más ampliamente, como la opinión de un experto o un grupo de expertos e indicadores de mercado (Hofer et al., 2015). Flores, Stading & Klassen (2007) mencionan que las Pymes aplican el criterio, conteo o encuesta para pronosticar. Como se observa, un problema grave para las Pymes es la falta de investigación y desarrollo, además de los altos costos operativos, lo que dificulta el acceso a grandes préstamos de los bancos. Estas empresas se ven afectadas por los altos impuestos, los costos de la seguridad social y la protección del empleo afectan los incentivos para la creación, operación y desarrollo de las empresas, alentando el desarrollo del sector formal. (OCDE, 2013).

Hanke and Wicher (2010) mencionan que en la mayoría de las empresas regionales se pronostica por intuición, por lo que es necesario reducir el grado de preocupación en las empresas. Smith III et al. (1996) mencionan que el pronóstico juega un papel esencial en cada área funcional de gestión. Los métodos de pronóstico pueden involucrar modelos matemáticos, predicciones subjetivas o intuitivas, o pueden incluir una combinación de estos (Mendez & Lopez 2014). Los pronósticos a corto plazo son necesarios para una organización. Sin embargo, estos se utilizan con mayor frecuencia en las áreas de marketing, producción y administración. Los promedios móviles, suavización exponencial y extrapolación de tendencias son típicos en las proyecciones a corto plazo (Heizer & Render, 2010). Cualquier pronóstico pretende ser útil a partir de la información disponible, y aplicar la técnica más adecuada para los diferentes patrones que exige (Krajewski, Ritzman & Malhotra, 2008). El modelo que elija cada empresa depende del horizonte a pronosticar, la disponibilidad de los datos y la precisión requerida, el presupuesto para las estimaciones y el personal calificado para el cálculo (Chase, Jacobs & Aquilano, 2014).

Algunas de las técnicas de pronóstico son el análisis de series de tiempo que implica el uso de datos pasados para predecir el futuro. Estos métodos analizan ciclos, ventas estacionales y factores aleatorios que podrían afectar el pronóstico. Otras técnicas que utilizan datos históricos son los métodos de correlación. El análisis de regresión se utiliza para correlacionar datos históricos con una o más variables. Cualquier estimación pretende ser útil a partir de la información disponible y aplicar la técnica a la más adecuada para los diferentes patrones que exigen (Krajewsky et al. 2008).

Algunos ejemplos de estos métodos de pronóstico pueden ser un promedio simple donde el patrón horizontal de una serie de tiempo se basa en el promedio de las demandas, promedios móviles simples donde la aplicación de este método requiere simplemente calcular la demanda promedio para los períodos más recientes, para usarlo como pronóstico para el próximo período, el promedio móvil ponderado donde cada una de las demandas históricas que intervienen en el promedio puede tener su ponderación y la suma de los pesos debe ser igual a 1.0, el promedio se obtiene multiplicando la ponderación por el valor de dicho período y agregando los productos, el suavizado exponencial de Brown es un método que utiliza un promedio ponderado de los valores pasados de una serie de tiempo para obtener un pronóstico a corto plazo, El modelo de Winter es el método indicado cuando se tiene series de tiempo con un componente estacional claramente definido, cada uno de los componentes del tiempo, el promedio suavizado, la tendencia suavizada y el factor estacional se combinan por separado para obtener el pronóstico (Krajewski et al. 2008), Suavizado exponencial de Holt es un método de promedio móvil ponderado muy refinado que permite calcular el promedio de una serie de tiempo, asignando a las demandas recientes un mayor peso que a los anteriores (Zuluaga, Molina & Guisao, 2011).

Algunos autores identifican el comportamiento y las condiciones de los productos mediante la aplicación de métodos a los artículos más críticos. Debido a que la mayoría de los estudios en el área de gestión de inventario tienen como objetivo reducir el costo o el espacio inmovilizado en los inventarios y, por lo tanto, utilizar el volumen y las características del producto (p. ej. necesidades de espacio o costo unitario) (Van Kampen, Akkerman & van Donk, 2012). El método ABC determina cuáles son los artículos más críticos. (Flores & Whybark, 1988). Esta técnica clasifica los productos según el valor de la demanda o el volumen de la demanda. (Van Kampen et al., 2012), de modo que la categoría A representa el 80% del valor de los ingresos acumulados y, por lo general, representa el 20% de los artículos. La categoría B aporta el 15% del valor de los ingresos acumulados y representa el 80% -90% de los artículos y los artículos C son el último 5% de los ingresos (Dhoka & Choudary, 2013). Sin embargo, los libros de texto de gestión de operaciones y gestión de la cadena de suministro no han seguido su ejemplo, pero continúan discutiendo el análisis ABC basado en la idea del volumen anual en dólares. El objetivo de la técnica es enfocarse en unos pocos productos que representan la mayor parte de los ingresos, obteniendo reducciones significativas en los costos de inventario (Dhoka & Choudary, 2013). Los inventarios de grandes cantidades de productos terminados, repuestos y materias primas complican el manejo del material, por lo que responden al menos dos preguntas: cuánto pedir y cuándo ordenar (Ravinder & Misra, 2014).

Zuluaga, et al. (2011) menciona que las ventajas que ofrecen los pronósticos de demanda son operativas y estratégicas, y minimizan el exceso de inventario. Los pronósticos mejoran el nivel de servicio al cliente debido al equilibrio entre la oferta y la demanda (Efendigil, Önüt & Kahraman 2009).

La precisión del pronóstico de la demanda afecta significativamente los niveles de inventario, los costos y los niveles de satisfacción del cliente. Para configurar todos los pasos logísticos necesarios para producir y vender un producto, los gerentes deben confiar en sistemas de pronóstico eficientes y precisos (Thomassey, Happiette & Castelain, 2002). También las cifras mejoradas de pronóstico de la demanda desempeñan un papel importante en la planificación de productos de corta vida (Raju, Kang, Moroz, Clement, Hopwell & Duffy, 2015). Tener una visión clara de la demanda futura permite a las empresas reducir sus costos, mejorar y adaptar el servicio ofrecido a sus clientes. (Slimani, Farissi & Achchab, 2015). Frank, Garg, Raheja & Sztandera (2003) pronosticaron la demanda mediante tres diferentes métodos: suavización exponencial, método Winter y RNA. Afirmaron que la precisión del pronóstico del método RNA es mayor que la de las otras dos técnicas. Escoda, Ortega, Sanz & Herms (1997) comparó el método RNA, RNA difuso y el de Winter para pronosticar la demanda. Tenían 73 puntos de datos históricos y utilizaron 59 de ellos en la etapa de capacitación y 14 en la etapa de validación.

Las redes neuronales artificiales (RNAs) están inspiradas en el comportamiento del cerebro humano, especialmente debido a las neuronas y sus conexiones. Intenta crear modelos artificiales para resolver problemas que son difíciles de resolver utilizando técnicas algorítmicas convencionales. Una definición matemática de una red neuronal es "un gráfico dirigido que consiste en nodos con enlaces sinápticos y enlaces de activación" (Haykin, 2009). Una red neuronal tiene un conjunto de *entradas* ( $x$ ), de  $n$  componentes, un conjunto de *sinapsis* que se caracteriza por un *peso* o *fuerzas* propias ( $W$ ), que representan la interacción entre la entrada de sinapsis ( $j$ ) conectada a la neurona ( $k$ ) se multiplica por el peso sináptico ( $W_{kj}$ ), un *sumador* para sumar las señales de entrada ponderadas por las respectivas fuerzas sinápticas de la neurona, una *función de activación* para limitar la amplitud de la salida de una neurona y la *salida* que es proporcionada por la función de salida ( $Y_k$ ), se puede observar una representación gráfica de la misma en la Figura 1, que forma la base para diseñar una gran familia de redes neuronales (Haykin, 2009).

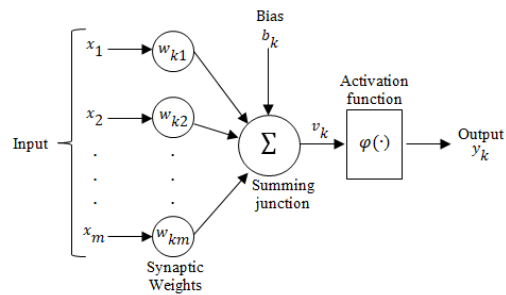


Figura 1. Modelo no lineal de una red neuronal

Fuente: Haykin, 2009

RNAs fueron aplicadas por primera vez en 1964; cuando se utilizó una RNA lineal adaptable para el pronóstico del clima debido a la ausencia del algoritmo de entrenamiento para RNA multicapa. Los pronósticos de períodos múltiples es un modelo único que genera simultáneamente los pronósticos de períodos múltiples, es decir, una RNA con múltiples salidas (Figura 1). La combinación del modelado no lineal y el aprendizaje mediante los datos hacen que las herramientas flexibles de modelado general de una RNA sean atractivas para su aplicación en la realización de pronósticos. Aunque existen numerosas aplicaciones de RNA para pronosticar con resultados satisfactorios, estas no tienen una metodología estandarizada que garantice una buena precisión de las estimaciones. (Salazar & Cabrera, 2007). Las RNAs son modelos flexibles no lineales basados en datos que tienen propiedades atractivas para el pronóstico. Los métodos estadísticos son eficientes para los datos con patrones estacionales o de tendencia, mientras que las RNAs acomodan los datos influenciados por el caso especial, como una promoción o una fluctuación de demanda de crisis extrema (Kourentzes, 2013).

Una red neuronal toma varias entradas binarias donde  $x_1, x_2, x_3, \dots$  son variables independientes y contienen una o más capas que están ocultas de los nodos de entrada a salida, como se puede observar en la figura 2. Se ha demostrado que las RNAs son eficientes en el modelado de problemas complejos y poco conocidos para los cuales se recopilan suficientes datos (Dhar & Stein, 1997). ANN es una tecnología que se ha utilizado principalmente para la predicción, agrupamiento, clasificación y alerta de patrones anormales. La capacidad de los ejemplos de aprendizaje es probablemente la propiedad vital de las redes neuronales en las aplicaciones y puede usarse para entrenar a la red con los registros de la respuesta pasada de un sistema complejo (Wei, Zhang & Li, 1997).




Figura 2. Red neuronal multicapa con multiples salidas entrenadas

Fuente: Haykin, 2009.

Se han propuesto muchos modelos de RNA, un perceptrón de múltiples capas es una red de alimentación que se compone de varias capas de neuronas entre las entradas y salidas que permiten decidir sobre áreas más complejas que un sensor de nivel único (Hilera & Martinez, 1995). Las redes neuronales artificiales pueden aprender de la experiencia, generalizar de casos anteriores a casos nuevos, a características abstractas esenciales de entradas que representan información irrelevante, etc. Backpropagation (propagación inversa) es un tipo de red neuronal que se ha aplicado para resolver muchos problemas debido a la facilidad de aprendizaje, por ejemplo, control de robots, predicción, reconocimiento de patrones. Este algoritmo se aplica con más de dos capas que consiste en aprender un conjunto predefinido de pares de entrada-salida como ejemplo, utilizando un ciclo de propagación-adaptación de dos fases: primero se aplica un patrón de entrada;  $X_p: xp1, xp2, \dots, xpN$  como estímulo para la primera capa de las neuronas de la red, se propaga a través de todas las capas superiores hasta generar la salida deseada que la red debe realizar:  $d1, d2, \dots, dM$ , el resultado obtenido en las neuronas de salida se compara con la salida a obtener, y se calcula un valor de error para cada neurona de salida (Hilera & Martinez, 1995). La función de activación también se denomina función de transferencia, y determina la relación entre las entradas y salidas de un nodo y una red. Estos pueden ser (Zhang, Patuwo & Hu, 1998):

La función sigmoidea (logística):

$$f(x) = (1 + \exp(-x))^{-1} \quad (1)$$

La función tangente hiperbólica (tanh):

$$f(x) = (\exp \exp (x) - \exp(-x))/\exp(x) + \exp(-x)) \quad (2)$$

La función seno y coseno:

$$f(x) = \sin \sin (x) \text{ or } f(x) = \cos(x) \quad (3)$$

La function lineal:

$$f(x) = x \quad (4)$$

Zhang et al. (1998) también menciona que “las medidas de desempeño deben calcularse en función de los resultados reescaldados, que un entrenamiento y una muestra de prueba generalmente requieren para

construir un pronóstico de RNA y esto puede afectar el desempeño de la RNA, existen muchas medidas de desempeño para un pronosticador de ANN como el tiempo del modelado y el tiempo de entrenamiento, la medida final y más crítica del rendimiento es la precisión de predicción que puede lograr más allá de los datos de entrenamiento y una medida de precisión a menudo definida en términos del error de pronóstico, que es la diferencia entre el real (deseo) y el valor pronosticado. Los más utilizados son:

Desviación media absoluta MAD (Mean Absolute Deviation en inglés):

$$(MAD) = \frac{\sum |e_t|}{N} \quad (5)$$

Suma del error al cuadrado SSE (Sum of Squared Error en inglés):

$$(SSE) = \sum (e_t)^2 \quad (6)$$

Error cuadrático medio MSE (Mean Squared Error en inglés):

$$(MSE) = \frac{\sum (e_t)^2}{N} \quad (7)$$

Error cuadrático medio RMSE (Root Mean Squared Error en inglés):

$$(RMSE) = \sqrt{MSE} \quad (8)$$

Error porcentual absoluto medio MAPE (Mean Absolute Percentage Error en inglés):

$$(MAPE) = \frac{1}{N} \sum \frac{|e_t|}{y_t} * 100 \quad (9)$$

## METODOS UTILIZADOS EN LA INVESTIGACION

Para garantizar la selección de la técnica de pronóstico correcta para alcanzar el pronóstico de demanda con el mínimo error, fue necesario pasar por varias fases. Primero, se recopiló el historial de demanda de la Pyme. Cuando se encuentra más información disponible, los factores de nivel y tendencia pueden ser actualizados. En este estudio, los métodos utilizados fueron en primera instancia la clasificación ABC que permitió dividir los artículos en tres categorías A,B, C: siendo los artículos A los más valiosos que representan el 70% de los ingresos y B y C siendo los artículos menos valiosos. De esta manera, el proyecto pudo centrarse en los productos que representan un mayor valor monetario para la empresa. Una vez que se obtuvo esa información, las técnicas de pronóstico tradicionales se aplicaron solo para los artículos A. Debido a que los métodos de series de tiempo se utilizan para hacer análisis detallados de los patrones históricos de una variable a lo largo del tiempo y proyectarlos hacia el futuro.

El primer método de series de tiempo que se aplicó fue el Promedio simple, que se utiliza para series estabilizadas y el entorno generalmente no está encadenado. El segundo método fue Promedio móvil simple, la aplicación de este método requiere calcular la demanda promedio para los  $n$  períodos más recientes, para usarlo como un pronóstico para el próximo período. El tercer método es promedio móvil ponderado; cada una de las demandas históricas involucradas en el promedio puede tener su propio peso, y la suma de los pesos debe ser igual a 1.0, el promedio se obtiene multiplicando el peso por el valor de dicho período y agregando los productos (Krajewski et al. 2008). El siguiente método tradicional de series de tiempo que se aplicó fue el modelo de Holt; que es óptimo para los patrones de demanda que presentan una tendencia y un patrón estacional constante, en el que se pretende eliminar el impacto de elementos históricos irregulares al enfocarse en períodos de demanda reciente agregando una beta ( $\beta$ ) constante de suavización, cuya función es reducir el error que ocurre entre la demanda real y el pronóstico (Hanke & Wichern, 2010).

Posteriormente se aplicó el método de Brown a los datos históricos, que consisten en dos suavizaciones exponenciales a partir de las cuales se obtendrá el valor estimado o el pronóstico deseado calculado con una expresión simple. Primero aplicado a los valores observados en la serie de tiempo y el segundo a la serie atenuada obtenida por la primera atenuación. Y el último método tradicional aplicado fue el método de Winters, que utiliza tres pesos o parámetros de suavización ( $\alpha$  y  $\beta$ ) para actualizar los componentes en cada período. Utiliza el nivel, la tendencia y los componentes estacionales para generar pronósticos. Después de la aplicación de los métodos mencionados, se calculó el error promedio durante los  $n$  períodos. Una medición de error común es el Error de porcentaje absoluto medio (MAPE) que expresa el error relativo a la magnitud de la demanda (Hanke & Wichern, 2010). Sin embargo, el error presentado por los pronósticos aplicados fue alto; por lo cual se decidió hacer uso de las redes neuronales artificiales (ANN) para observar si la tasa de error disminuía. Debido a que hay muchas formas diferentes de construir e implementar una red neuronal para el pronóstico, a través de la revisión de la literatura se observó que la mayoría de los estudios utilizan el algoritmo Backpropagation aplicado a los perceptrones multicapa (MLP) mostrando buenos resultados. Sin embargo, existen pocas referencias de trabajos desarrollados con la aplicación de esta técnica.

Los ANN podrían reducir la tasa de error si comparamos la tasa con las técnicas de pronóstico ordinarias. Hay tres puntos básicos de los perceptrones multicapa: uno es que cada neurona en la red incluye una función de activación no lineal que es diferenciable, la red contiene una o más capas que están ocultas en los nodos de entrada y salida y la red exhibe un alto grado de conectividad, cuya extensión está determinada por los pesos sinápticos de la red. Antes de que una RNA pueda realizar cualquier tipo de tarea, primero tiene que estar capacitado para hacerlo. Un entrenamiento común "para perceptrones multicapa es el algoritmo de backpropagation. El entrenamiento se desarrolla en dos fases: en la fase de avance los pesos sinápticos de la red son fijos, y la señal de entrada se propaga a través de la red, capa por capa hasta llegar a la salida. En la fase hacia atrás, se produce una señal de error al comparar la salida de la red con la respuesta deseada. La señal de error resultante se propaga a través de la red, nuevamente capa por capa, pero esta vez la propagación se realiza en la dirección hacia atrás ". Al implementar el método, los valores de demanda se representaron como vectores de entrada para generar la capacidad de aprendizaje y comparar la diferencia entre los datos de salida deseados con la salida obtenida para calcular el error de esta manera (Haykin, S. (2009).

El algoritmo de entrenamiento utilizado para encontrar los pesos que minimizan el error fue backpropagation, que se representa matemáticamente como:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (10)$$

Donde  $v_j(n)$  producido en la entrada de la función de activación asociada con la neurona  $j$  es por lo tanto donde  $m$  el numero total de entradas (excluyendo bias) es aplicado a neurona  $j$ . El peso sináptico  $w_{j0}$  es igual a bias  $b_j$  aplicado a la neurona  $j$ . Por lo tanto, la señal de función  $y_i(n)$  que aparece en la salida de la neurona  $j$  es la iteración en  $n$ .

## METODOLOGIA

For the elaboration of the proposal it was made the following methodology:

1. Problem approach: La empresa seleccionada se dedica a la fabricación de muebles contemporáneos con un proceso artesanal y de carpintería tradicional lo que le da a sus productos la calidad característica que los distingue de la competencia. Inició operaciones en la ciudad de Puebla en el año 2002. Actualmente cuenta con 40 trabajadores Operativos y 8 trabajadores Administrativos. Está empresa fue representante del talento mexicano y fue seleccionada por PROMÉXICO para participar en la exposición de mobiliario denominada Wanted Desing en la ciudad de Nueva York en el año 2017. Participa en distintos meses del año en las Exposiciones de Muebles más importantes de México como son: Expo Internacional del Mueble (Guadalajara, Jalisco), Decoestylo (CDMX) y Expo Habitat (CDMX). Cuenta con una tienda y sus principales clientes en la ciudad de Puebla. El resto de los clientes se encuentran en: CDMX, Morelos, Estado de México, Jalisco, Michoacán, Chihuahua y Coahuila. Su portafolio incluye 8 colecciones diferentes de muebles en el que cada una incluye: Recamaras, Comedores, Muebles de TV, Mesas de centro y accesorios.  
Está dividida en 4 áreas principales:
  - a) Comercial, que se encarga de generar y recibir pedidos, realizar el Plan de Producción, cobranza y entregas a clientes.
  - b) Logística, que incluye los departamentos de Almacén de Materia prima, Compras, Inventarios, Almacén de producto terminado, Empaque, Embalaje y Transporte a clientes finales.
  - c) Producción, que incluye las áreas de Diseño, Carpintería, Fondo, Acabado y Control de Calidad.
  - d) Administración, que se encarga de la gestión de los bienes capitales y humanos de la empresa.
2. Data: La empresa realiza la planeación de compra de materia prima y la producción de acuerdo a como van levantando los pedidos de los clientes con un horizonte de planeación de 15 días. No se cuenta con un pronóstico de la demanda y no se tiene una capacidad limitada de almacenamiento de producto terminado. Para el presente caso de estudio los autores se dieron a la tarea de obtener los datos históricos de la demanda de los productos que la empresa fabrica. Fue proporcionada la información de los meses comprendidos entre Diciembre de 2016 a Noviembre de 2017

En este estudio para obtener el pronóstico más efectivo que arrojara el error mínimo, se incluyeron las siguientes fases:

**Fase uno:** Fue necesario llevar a cabo la clasificación ABC para concentrarse únicamente en los productos “A” que son los más producidos y demandados durante el año de acuerdo con los datos históricos proporcionados.

Tabla 1. Resultados de la clasificación ABC

Artículo	Consumo	Porcentaje acumulado	ABC
Lampara	1338	28%	A
Silla	1322	56%	
Mesa	318	62%	
Buro	221	70%	
Cabecera	176	72%	B
Buffet	151	74%	
Respaldo	135	76%	
Espejo	129	79%	
Base de cama	127	82%	
Cajonera	102	84%	
Consola	59	85%	
Banco	54	86%	
Repisa	54	87%	
Sillon	51	88%	
Modulos	48	89%	C
Otros	507	100%	
Total	4792		

*Fuente: (Elaboración propia)*

Los datos históricos de los productos que fueron clasificados como A se recopilaron y concentraron en una tabla. Como se puede observar en la tabla 2 y la tabla 3.

Tabla 2. Daros historicos de la demanda de productos A (2017)

2017	Dic	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov
Buro	27	25	20	12	13	14	10	18	20	21	18	17
Lampara	52	51	152	131	166	177	125	99	104	100	93	90
Mesa	13	19	40	23	30	20	26	23	43	42	22	20
Silla	65	82	105	157	134	70	117	124	194	139	86	64

*Fuente: (Elaboración propia)*

Tabla 3. Datos historicos de la demanda de productos A (2016)

2016	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Buro	19	28	14	5	12	27	33	14	16	20	16	27
Lampara	9	11	9	3	12	12	89	9	10	11	8	10
Mesa	30	25	60	65	60	80	76	80	95	85	90	52
Silla	17	34	11	4	11	12	20	24	30	32	20	13

*Fuente: (Elaboración propia)*

**Fase dos:** La implementación de las técnicas de pronóstico tradicionales se aplicó a los 4 productos principales de la empresa, comenzando con el promedio simple del método de series de tiempo, siguiendo

con el promedio móvil simple para luego utilizar el promedio móvil ponderado y proceder con los métodos de Holt, Brown y finalmente método de Winters. Esto permite hacer un análisis comparativo de los porcentajes de error. Se pudo observar el alto error que reflejaba el uso de dichas técnicas. Esto puede deberse a la tendencia de la demanda de la empresa. Lo que nos lleva a optar por otra técnica de pronóstico.

**Fase tres:** Los datos históricos fueron analizados para definir la mejor manera de calcular una demanda pronosticada mediante el uso de una red neuronal. Para esta investigación se decidió desarrollar una red multicapa con método de entrenamiento del algoritmo backpropagation que asigna ciertas formas de comportamiento a todas sus neuronas a través de una especificación del algoritmo de aprendizaje de corrección de errores. Debido a que la compañía tiene un registro bajo de sus ventas mensuales, se utilizó la recopilación de datos históricos de dos años. La elaboración de la red neuronal se llevó a cabo mediante la herramienta MATLAB 18. Primero las ventas de 2016 se tomaron como entradas y las ventas de 2017 se tomaron como salidas deseadas para entrenar a la red y obtener un pronóstico para 2017. La función de aprendizaje adaptativo (adaptive learning function) que se estableció fue LearnGdm, que calcula la función de aprendizaje de cambio de peso y errores, y el algoritmo de entrenamiento fue Trainlm, que es el algoritmo de backpropagation más rápido del software MATLAB. Después de varias pruebas, el número de capas ocultas varío entre 2 y 20 buscando la mejor opción para cada producto. Como meta se estableció un margen de  $1E-2$  a  $1E-5$  que dio el mejor resultado. Cuanto más entrenada estaba la red, menos posibilidades de error tenía. Después de la información obtenida de esa red capacitada, los resultados se colocaron como entradas para predecir la demanda de 2018.

**Fase cuatro:** Se comparó el error (MAPE) entre los métodos de pronóstico aplicados.

## RESULTADOS

De acuerdo a los datos históricos del año 2017 proporcionados por la empresa, se analizaron y aplicaron seis métodos tradicionales cuantitativos: promedio simple, promedio móvil simple, promedio móvil ponderado, suavización exponencial de Brown, modelo de Winter, modelo de Holt, para determinar la demanda futura que la empresa tendrá los próximos tres meses. Los pronósticos realizados con los métodos mencionados y el error calculado de cada uno de ellos, ayuda a definir cuál es la mejor técnica para pronosticar la demanda de dicha empresa. En la siguiente tabla se reflejan los porcentajes de los errores resultantes de cada uno de los pronósticos aplicados como se puede observar en la Tabla 4.

Tabla 4. Errores de los metodos de pronostico aplicados

Articulo	Promedio simple	Promedio movil simple	Promedio movil ponderado	Holt	Brown	Winters	RNAs
Silla	36%	46%	44%	32%	34%	41%	11%
Mesa	32%	33%	33%	26%	30%	33%	10%
Lampara	29%	29%	26%	29%	17%	43%	10%
Buro	35%	33%	29%	22%	21%	26%	11%

*Fuente: (Elaboracion propia)*

El término error se refiere a la diferencia entre los valores pronosticados y los datos reales. Se puede observar que en los modelos de suavizado exponencial de Brown y Holt, se refleja el porcentaje de error más bajo, siendo para silla 32%, mesa 26%, lámpara 17% y buró 21%. Debido a que los métodos de suavización exponencial doble, son los más adecuados para este tipo de demandas cuya variabilidad no presenta una tendencia o estacionalidad. En este método, los eventos más recientes son indicadores del futuro que los del pasado más lejano. Para los productos buró y lámpara se pronosticó la demanda del siguiente mes con el método Brown como se muestra en la tabla 5.

Tabla 5. Demanda pronosticada con método Brown

	Dic	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Buro	27	25	20	12	13	14	10	18	20	21	18	17	18
Lámpara	52	51	152	131	166	177	125	99	104	100	93	90	92

*Fuente: (Elaboración propia)*

For the case of the other two products classification A, which are: Tables and Chairs, the forecast was made using the Holt Exponential Smoothing Method and gave us forecast results for December, January and February shown in the table 6:

Tabla 6. Demanda pronosticada con método Holt

	Dic	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb
Mesa	13	19	40	23	30	20	26	23	43	42	22	20	31	33	34
Silla	65	82	105	157	134	70	117	124	194	139	86	64	124	123	123

*Fuente: (Elaboracion propia)*

Después de varios intentos, a través de las redes entrenadas los resultados fueron reflejando errores de pronostico comparados con los altos porcentajes de error reflejados en los pronósticos tradicionales como se puede observar en la tabla 7, tabla 8, tabla 9 y tabla 10, representadas gráficamente en la figura 3, figura 4, figura 5 y figura 6.

Tabla 7. Demanda pronosticada Buro con 10 capas y 80 entrenamientos

<b>Buro</b>					
<b>Entradas</b>	<b>Salidas</b>	<b>Pronóstico 2017</b>	<b>Error</b>	<b>MAPE</b>	<b>Pronóstico 2018</b>
19	27	26.7489	0.2511	0.0093	14.2865
28	25	24.6055	0.3945	0.01578	10
14	20	17.9782	2.0218	0.10109	21.261
5	12	12.7453	0.7453	0.06210833	24.2886
12	13	24.2886	11.2886	0.86835385	19.1297
27	14	14.2865	0.2865	0.02046429	17.9782
33	10	10	0	0	10.9221
14	18	17.9782	0.0218	0.00121111	26.2371
16	20	18.3632	1.6368	0.08184	21.261
20	21	21.261	0.261	0.01242857	10.1145
16	18	18.3632	0.3632	0.02017778	26.2371
16	17	18.3632	1.3632	0.08018824	21.3678

				11%	
--	--	--	--	-----	--

Fuente: (Elaboración propia)

Tabla 8. Demanda pronosticada Lámpara con 10 capas y 10 entrenamientos

<b>Lámpara</b>					
<b>Entradas</b>	<b>Salidas</b>	<b>Pronóstico 2017</b>	<b>Error</b>	<b>MAPE</b>	<b>Pronóstico 2018</b>
30	51	55.4776	4.4776	0.08779608	90.2045
25	152	151.2512	0.7488	0.00492632	104.3559
60	131	132.9034	-1.9034	0.01452977	104.3559
65	166	135.2566	30.7434	0.1852012	104.3559
60	177	132.9034	44.0966	0.24913333	104.3559
80	125	87.4972	37.5028	0.3000224	104.3559
76	99	90.0965	8.9035	0.08993434	104.1347
80	104	87.4972	16.5028	0.15868077	104.3515
95	100	102.0693	-2.0693	0.020693	104.2527
85	93	88.3022	4.6978	0.05051398	100.8532
90	90	98.6995	8.6995	0.09666111	98.6995
52	96	95.9408	0.0592	0.00061667	102.8273
				10%	

Fuente: (Elaboracion propia)

Tabla 9. Demanda pronosticada Mesa con 10 capas y 22 entrenamientos

<b>Mesa</b>					
<b>Salidas</b>	<b>Entradas</b>	<b>Prónostico 2017</b>	<b>Error</b>	<b>MAPE</b>	<b>Prónostico 2018</b>
17	19	19	0	0	19.7278
34	40	23.2858	16.7142	0.417855	26.6892
11	23	21.5	1.5	0.065217391	43
4	30	32.7491	-2.7491	0.091636667	41.9973
11	20	21.5	1.5	0.075	21.4987
12	26	22.3521	3.6479	0.140303846	43
20	23	21.4987	1.5013	0.065273913	43
24	43	43	0	0	26.6894
30	42	41.9973	0.0027	6.42857E-05	26.6894
32	22	21.9999	0.0001	4.54545E-06	42.9975
20	20	21.4987	-1.4987	0.074935	21.4987
13	17	21.9521	-4.9521	0.2913	19
				10%	

Fuente: (Elaboración propia)

Tabla 10. Demanda pronosticada Silla con 10 capas y 123 entrenamientos

Silla					
Entradas	Salidas	Prógnostico 2017	Error	MAPE	Prógnostico 2018
83	82	81.9986	0.0014	1.70732E-05	137.1065
36	105	95.16446	9.8354	0.093670476	64.0001
51	157	193.9988	36.9988	0.235661146	64.0001
33	134	135.4149	1.4149	0.010558955	64.0001
70	70	69.9986	0.0011	1.57143E-05	69.9989
35	117	96.9942	20.0058	0.170989744	64.0001
37	124	94.685	29.315	0.23641129	64.0001
32	194	190.4745	3.5255	0.01817268	64.0001
45	139	138.9486	0.0514	0.000369784	64.0001
38	86	94.5729	8.5729	0.099684884	64.0007
40	64	94.7709	30.7709	0.480795313	127.4447
65	84	84.0001	0.0001	1.19048E-06	64.5327
				11%	

Fuente: (Elaboración propia)

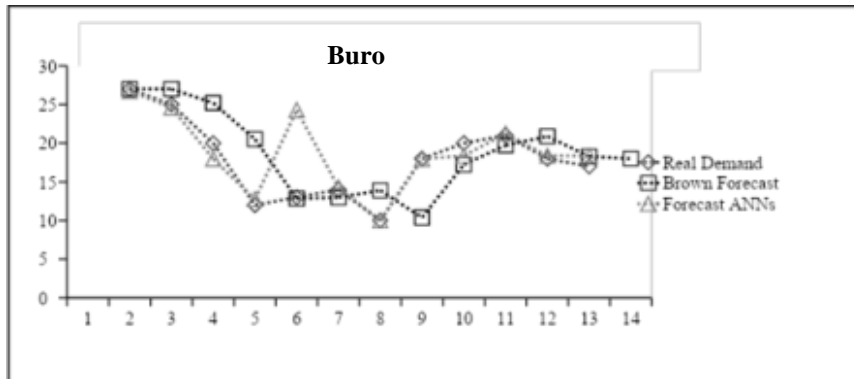


Figura 3. Comparación grafica de la demanda real y pronosticada para Buro

Fuente: (Elaboración propia)

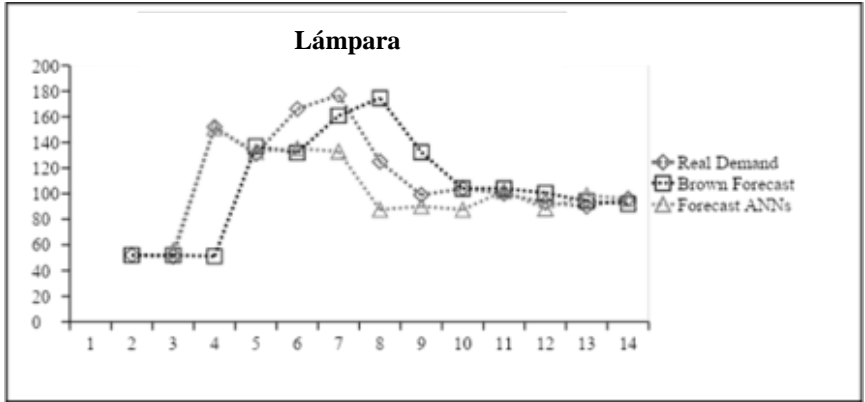


Figura 4. Comparación grafica de la demanda real y pronosticada para Lámpara

Fuente: (Elaboración propia)

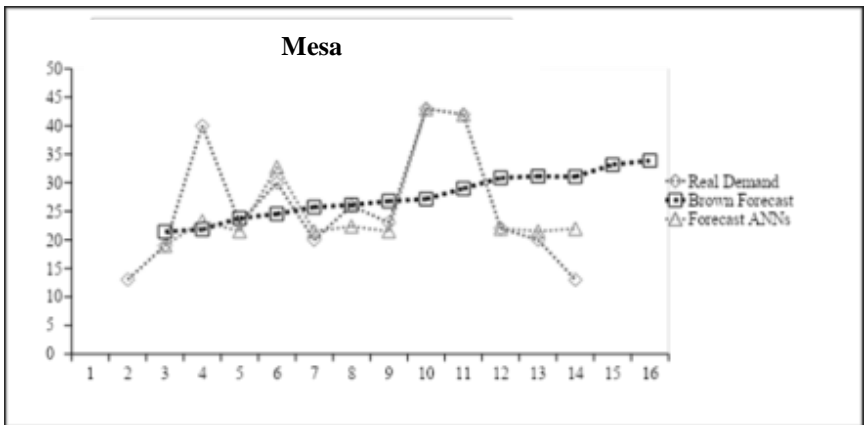


Figura 5. Comparación grafica de la demanda real y pronosticada para Mesa

Fuente: (Elaboración propia)

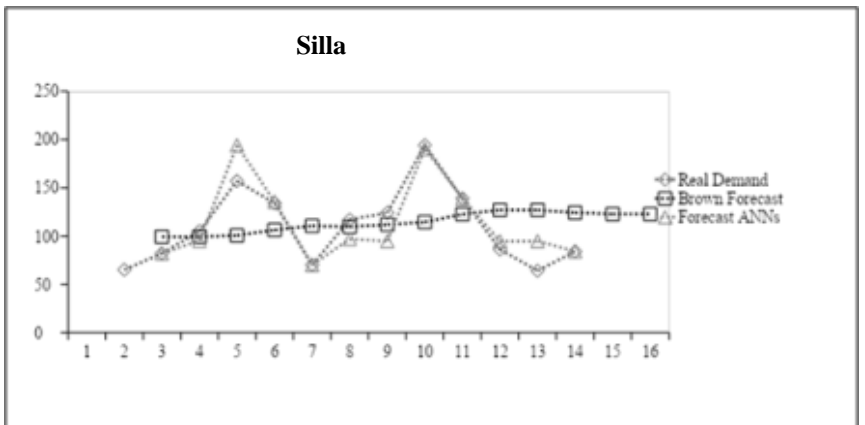


Figura 6. Comparación grafica de la demanda real y pronosticada para Silla

Fuente: (Elaboración propia)

## CONCLUSION

Un pronóstico es un elemento vital para cualquier organización tales como las Pymes, gracias a estas predicciones se pueden tomar decisiones importantes para la gestión del producto. Una estimación debe ser la base de la planificación de la producción y la oferta de la demanda. Con un buen pronóstico la producción, logística y las operaciones de una Pyme planificará sus capacidades, distribuirá sus instalaciones y personal, y programará sus producciones e inventarios diarios. Es posible observar que con algunas herramientas simples, y sin mucha inversión, los empresarios pueden apoyar a las Pymes y lograr sus objetivos de producción y servicio al cliente.

Un paso importante en la selección de una técnica de pronóstico apropiada es identificar patrones de datos que existen dentro de una serie de tiempo. Una vez identificados, se puede utilizar el método de pronóstico más adecuado para cada caso.

Los pronósticos son específicos para cada artículo; es vital considerar la variabilidad de la demanda para aplicar el método apropiado debido a que podría garantizar una mejor estimación. En este caso, hubo un método de suavización exponencial doble, lo que permitirá a la empresa mejorar los recursos adquiridos y eliminar la incertidumbre de los pedidos. Es importante saber que los datos deben analizarse y actualizarse, tomando en cuenta los eventos no planeados debido a los constantes cambios de la demanda.

Debido a la ineficiencia de los datos históricos, los errores pueden dar lugar a un mal pronóstico, pero podría ser posible minimizar el error a través de la RNA. Cuando se tiene una red neuronal artificial entrenada con más datos históricos, la neurona procesa la información proporcionada para obtener un resultado óptimo.

## REFERENCIAS

Acosta, M., Diaz, R., & Anaya, A. (2009). Review of techniques of multiple criteria decision analysis (MCDA) as a support to complex problems: Demand predictions. *Revista Científica Guillermo de Ockham*, 7(2), 91-110.

Alonso, P., & Villegas, E. (2005). La importancia de los criterios cualitativos de los pronósticos en los agronegocios. *Revista Mexicana de Agronegocios*, 9(16), 464-477.

Banco Interamericano de Desarrollo [BID]. (2010). *La logística de cargas en América Latina y el Caribe: una agenda para mejorar su desempeño*. Retrieved from: <https://publications.iadb.org/bitstream/handle/11319/6269/La%20log%C3%ADstica%20de%20cargas%20en%20Am%C3%A9rica%20Latina%20y%20el%20Caribe%3A%20una%20agenda%20para%20mejorar%20su%20desempe%C3%B1o.pdf?sequence=1>

Banco Interamericano de Desarrollo [BID]. (2011). *La logística como motor de la competitividad en América Latina y el Caribe*. Banco Interamericano de Desarrollo, Retrieved from: <https://publications.iadb.org/bitstream/handle/11319/5091/La%20log%C3%ADstica%20como%20motor%20de%20la%20competitividad%20en%20Am%C3%A9rica%20Latina%20y%20el%20Caribe.pdf?sequence=1&isAllowed=y>

Chang, P., & Wang, Y. (2006). Fuzzy Delphi and back-propagation model for sales forecasting in PCB industry. *Expert Systems With Applications*, 30(4), 715-726.

Chase, R., Jacobs, F. & Aquilano N. (2014). *Operations and supply chain management 13th ed.* Mexico: Mc Graw Hill.

Comisión Económica para América Latina y el Caribe [CEPAL]. (2018). *Acerca de Microempresas y Pymes*. Retrieved from: <https://www.cepal.org/es/temas/pymes/acerca-microempresas-pymes>

Dhar, V., & Stein, R., (1997). *Seven methods for transforming corporate data into business intelligence*, Nueva Jersey: Prentice-Hall.

Dhoka, D., & Choudary, Y. (2013). ABC Classification for Inventory Optimization. *IOSR Journal of Business and Management*, 15(1), 38-41.

Efendigil, T., Önüt, S., & Kahraman, C. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: a comparative analysis. *Expert Systems with Applications*, 36(3), 6697–6707.

Escoda, I., Ortega, A., Sanz, A., & Herms, A. (1997). Demand forecast by neuro-fuzzy techniques. *Proceedings of the Sixth IEEE International Conference*, 3, 1381-1386.

Flores, B., & Whybark, D. (1988). Know Your ABC. *Management Decision*, 26(3), 20-24.

Flores, B., Stading, G., & Klassen, R. (2007). The business forecasting process: a comparison of differences between small and large Canadian manufacturing and service firms. *International Journal of Management and Enterprise Development*, 4(4), 387-402.

Frank, C., Garg, A., Raheja, A., & Sztandera, L. (2003). Forecasting women's apparel sales using mathematical modeling. *International Journal of Clothing Science & Technology*, 15(2), 107-125.

Gunasekaran, A., Rai, B., & Griffin, M. (2011). Resilience and competitiveness of small and medium size enterprises: An empirical research. *International Journal of Production Research*, 49(18), 5489–5509.

Hanke, J., & Wichern, D. (2010). *Business forecasting 9th ed.* Mexico: Pearson Education.

Haykin, S. (2009). *Neural Networks and Learning Machines*. Canada: Pearson Education.

Heizer, J., & Render, B. (2010). *Principles of operations management 8th ed.* Mexico: Pearson Educación

Hilera, J.R., & Martínez, V.J. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Madrid, España: RA-MA Editorial.

Hofer, P., Eisl, C., & Mayr, A. (2015). Forecasting in Austrian companies. *Journal of Applied Accounting Research*, 16(3), 359–382.

Instituto Nacional de Estadística y Geografía. [INEGI]. (2014). *Censos económicos 2014*. Retrieved from: [http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod\\_serv/contenidos/espanol/bvinegi/productos/nueva\\_estruc/702825077952.pdf](http://internet.contenidos.inegi.org.mx/contenidos/Productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/702825077952.pdf).

Instituto Nacional de Estadística y Geografía [INEGI]. (2018). *Sistema de Cuentas Nacionales de México*. Retrieved from <http://www.inegi.org.mx/est/contenidos/Proyectos/scN/>.

Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143(1), 198–206.

Krajewski, L., Ritzman, L., & Malhotra, M. (2008). *Operation management process and values chain 8th ed*. Mexico: Pearson Education.

Kumar, P., Herbert, M., & Rao, S. (2014). Demand forecasting Using Artificial Neural Network Based on Different Learning Methods: Comparative Analysis. *International journal for research in applied science and engineering technology*, 2(4), 364-374.

Lopez, E. Acosta, M. Espinoza, E. & Delfín, F. (2007). Globalization and its effects on the management of micro, small and medium enterprises and Latin America. *Equidad y desarrollo*, 8, 113-125.

Mendez, G., & Lopez, E. (2014). Methodology to demand forecasting under multiproduct environments and high variability. *Tecnura*, 18(40), 89-102.

Ministerio de Economía. (2011). *Evolución del desempeño logístico de las cadenas de suministro en México*. Retrieved from: <http://www.elogistica.economia.gob.mx/swb/work/models/elogistica/Resource/3/1/images/evolucion2011.pdf>

Ministerio de Economía. (2012), *Pequeñas empresas*. Retrieved from: <http://www.2006-2012.economia.gob.mx/mexico-emprende/empresas/mediana-empresa>.

Ministerio de Economía. (2012). *Pequeñas empresas*. Retrieved from <http://www.2006-2012.economia.gob.mx/mexico-emprende/empresas/pequena-empresa>.

Morlidge, S., & Player, S. (2010). *Future ready: How to master business forecasting*. Chichester, England: John Wiley & Sons.

Organización para la Cooperación y el Desarrollo Económicos [OCDE]. (2013). *Mexico: Key Issues and Policies*. Paris: OECD Publishing.

Organización para la Cooperación y el Desarrollo Económicos [OCDE]. (2017). *Enhancing the contributions of SMEs in a global and digitalised economy*. Retrieved from: <https://www.oecd.org/mcm/documents/C-MIN-2017-8-EN.pdf>

Raju Y., Kang P., Moroz A., Clement R., Hopwell., & Duffy A. (2015). Investigating the Demand for Short-shelf Life Food Products for SME Wholesalers. *International Journal of Social, Behavioral, Educational, Economic, Business and Industrial Engineering*, 9(6), 2051-2055.

Ravinder, H., & Misra, R. (2014). ABC Analysis For Inventory Management: Bridging The Gap Between Research And Classroom. *American Journal Of Business Education*, 7(3), 257-263.

Rubio, G. (2017). Multivariant perspective of forecasts in industrial SMEs of Ibagué (Colombia). *Revista Facultad de Ciencias Económicas: Investigación y Reflexión*, 15(2), 25-40.

Salazar, M., & Cabrera, M. (2007). Pronóstico de demanda por medio de redes neuronales artificiales. *Ingenierías, Universidad Autónoma de Nuevo León UANL*, 10 (35), 6-12.

- Salles, M. (2006). Decision making in SMEs and information requirements for competitive intelligence. *Production Planning & Control: The Management of Operations*, 17(3), 229-237.
- Schreier, C., Udomkit, N., & Macchi, L. (2016). Cultural and Intuitive Intelligence of SME's Leaders. *GSTF Journal on Business Review (GBR)*, 4(3), 15-20.
- Slimani I., Farissi I., & Achchab S. (2015). Artificial Neural Networks/or Demand Forecasting: Application Using Moroccan Supermarket Data. *15th International Conference on Intelligent Systems Design and Applications (ISDA)*, 266-271.
- Smith III, H., Herbig, P., Milewicz, J., & Golden, J. (1996). Differences in forecasting behavior between large and small firms. *Journal of Marketing Practice: Applied Marketing Science*, 2(1), 35-51.
- Soto P., & Dolan, S. (2004). *Las PYMES ante el desafío del siglo XXI: los nuevos mercados globales*. Mexico: Thomson.
- Taiwo, A., Ayodeji M. & Yusuf A. (2012). Impact of Small and Medium Enterprises on Economic Growth and Development. *American Journal of Business and Management*, 1(1), 18-22.
- Thomassey, S., Happiette, M., & Castelain, J.M. (2002). An automic textile sales forecast using fuzzy treatment of explanatory variables. *Journal of Textile and Apparel, Technology and Management*, 2(4), 1-15.
- van Kampen, T., Akkerman, R., & van Donk, D. (2012). SKU classification: a literature review and conceptual framework. *International Journal of Operations & Production Management*, 32(7), 850 – 876.
- Wei, S., Zhang, J., & Li, Z. (1997). A supplier-selecting system using a neural network. *IEEE international conference on intelligent processing systems*, 468- 471.
- Wiratmadja, I., Rumanti, A., Reynaldo R., & Kurniawati, A. (2016). Intuition Concept in Small and Medium Enterprises through Strategic Decision-Making. *International Review of Management and Marketing*, 6(8), 322-326.
- World Trade Organization [WTO]. (2016). *Informe sobre el comercio mundial 2016*. Retrieved from: [https://www.wto.org/spanish/res\\_s/booksp\\_s/world\\_trade\\_report16\\_s.pdf](https://www.wto.org/spanish/res_s/booksp_s/world_trade_report16_s.pdf)
- Zeballos, E. (2003). Micro, Small and Medium-sized Enterprises in Latin America. *CEPAL Review*, 79, 51- 68.
- Zhang G., Patuwo B., & Hu, M. (1998). Forecasting with artificial neural networks: The state of art. *International Journal of Forecasting*, 14(1), 35-62.
- Zuluaga M., Molina P., & Guisao G. (2011). Supply chain management strategies based on demand planning in Colombia. *Revista Politecnica*, 12, 1900-23510.