

## Uso de técnicas de pronósticos para la planeación del inventario de una PYME comercializadora en Tlaxcala, México

**Enríquez Zárate, Lucía Guadalupe; Rodríguez Lozada, Miguel Ángel**

Uso de técnicas de pronósticos para la planeación del inventario de una PYME comercializadora en Tlaxcala, México

RECAI Revista de Estudios en Contaduría, Administración e Informática, vol. 10, núm. 27, 2021

Universidad Autónoma del Estado de México, México

**Disponible en:** <https://www.redalyc.org/articulo.oa?id=637968303002>



Esta obra está bajo una Licencia Creative Commons Atribución-NoComercial-SinDerivar 4.0 Internacional.

## Uso de técnicas de pronósticos para la planeación del inventario de una PYME comercializadora en Tlaxcala, México

Lucía Guadalupe Enríquez Zárte lucia.gez1605@gmail.com

*Instituto Tecnológico de Apizaco, México*

Miguel Ángel Rodríguez Lozada

*Instituto Tecnológico de Apizaco, México*

RECAI Revista de Estudios en  
Contaduría, Administración e  
Infomática, vol. 10, núm. 27, 2021

Universidad Autónoma del Estado de  
México, México

Recepción: 10 Septiembre 2020  
Aprobación: 01 Diciembre 2020

Redalyc: [https://www.redalyc.org/  
articulo.oa?id=637968303002](https://www.redalyc.org/articulo.oa?id=637968303002)

**Resumen:** La presente investigación tiene como objetivo contribuir con herramientas de pronósticos que asistan al administrador de la PYME bajo análisis a anticipar las ventas futuras para tomar decisiones de compra más acertadas que optimicen los niveles de inventario. El estudio se realiza en una empresa comercializadora de materiales de construcción en Tlaxcala, utilizando los datos históricos de venta del cemento gris por su aportación al 50% de las utilidades globales del negocio. Se compararon tres prácticas observadas en el entorno local (promedio semanal del último año, promedio semanal del mes anterior y misma cantidad que la semana anterior) y cinco técnicas de pronósticos usualmente aplicadas en la literatura (regresión lineal simple, suavización exponencial, regresión no lineal, regresión por redes neuronales y metodología Box-Jenkins). Los resultados revelaron que, cualquier pronóstico cercano o igual a la media resultará aceptable cuando la serie de datos siga una distribución normal. Hallándose que el modelo no lineal (regresión logarítmica natural) se ajustó mejor a los datos por la naturaleza variable de la demanda, los pronósticos con valores cercanos a la media y el 88% de aciertos en el patrón de tendencia.

**Palabras clave:** Pronósticos de demanda, inventario, PYMES.

**Abstract:** This paper aims to provide forecasting tools that could assist the manager of the SME under analysis to anticipate future sales and make better purchasing decisions that improve inventory levels. The subject of the case study was a retail shop selling construction materials in Tlaxcala. On account of its contribution to 50% of the business' global profits, we used historical data of Portland cement sales. A comparison was performed among simple heuristics observed in the local environment (the weekly average of the last year, the weekly average of the previous month, and the same amount as the previous week) and forecasting techniques usually applied in the literature (simple linear regression, exponential smoothing, non-linear regression, and regression by neural networks). The results revealed that any forecasted value close, or equal to the mean will be acceptable when the data series follows a normal distribution. It was found that the non-linear model (natural logarithmic regression) fitted the data better due to the variable nature of the demand, the forecasts with values close to the mean, and 88% of correct answers in the trend pattern.

**Keywords:** Demand forecasts, inventory, SME.

### 1. Introducción

Las micro, pequeñas y medianas empresas (MIPYMES) desempeñan un papel fundamental en la economía del país. Aportan el mayor número de unidades económicas -99.8% del total nacional-, generan el 52.2% de ingresos y son la fuente de empleo más grande -aglutinan el 68.4%

del personal ocupado total- (INEGI, 2020). Sin embargo, son las que sufren un mayor impacto por la internacionalización de la economía y los cambios frecuentes (García y Nava, 2019).

Las empresas familiares constituyen la forma de organización empresarial más común en las PYMES (Aguirre y Armenta, 2012; Cleri, 2013 y Hernández, 2007). Éstas se caracterizan por su propiedad, control y gestión (Martínez, 2010). Es decir, la familia tiene posesión completa o mayoritaria del capital, el negocio es dirigido por sus fundadores o familiares y la administración es empírica y basada en una persona que no delega. Esta limitada habilidad en gestión y administración de los directivos de las PYMES las coloca en mayor riesgo de fracaso (de la Garza, Zavala, López y López, 2019).

Entre las problemáticas de carácter estratégico y operativo que enfrentan las PYMES están la informalidad respecto de los mecanismos de toma de decisiones y que el empresario no proyecta la empresa a mediano y largo plazo por el desconocimiento de las herramientas existentes (Beltrán, 2006).

El inventario es uno de los rubros con pérdidas significativas. Su administración es una actividad importante en las empresas comercializadoras por constituir una inversión cuantiosa -hasta el 35 o 40% de los activos totales- (Roscoe y McKeown, 1986), por lo que se espera de él el mayor rendimiento posible. Varios autores en la literatura científica coinciden que los inventarios representan las existencias de recursos que las organizaciones emplean para cumplir con sus objetivos. Según Cruz (2017) un inventario “consiste en un listado ordenado, detallado y valorado de los bienes de una empresa”. Por su parte, Eppen, Gould, Schmidt, Moore y Weatherford (2000) lo definen como “bienes ociosos almacenados, en espera de ser utilizados”. De manera que los objetivos que persigue toda gestión del inventario son, entre otros:

- Reducir imprevistos, manteniendo niveles de seguridad de inventario.
- Disminuir los costos de pedido, de mantener y por faltantes, programando eficientemente las compras.
- Mitigar las diferencias entre la oferta de la empresa y la demanda de los clientes.

La demanda representa una variable importante en el proceso de gestión del inventario (Agudelo y López, 2018) y su anticipación oportuna es vital para cualquier empresa en la toma de decisiones estratégicas y operativas, como en el abastecimiento óptimo de las necesidades de los clientes a un costo mínimo. Bien es sabido que, comprar cantidades en exceso aumentan los costos de almacenaje, reducen el espacio en bodega para otros artículos e incrementan el riesgo de merma, caducidad y obsolescencia; y comprar menos de lo necesario incurre en stockouts, generando pérdidas directas de ventas y de clientes.

Es relevante reconocer que la experiencia e intuición no son suficientes para tomar decisiones de compra en un entorno de incertidumbre. Muñoz (2014) afirma que “el dimensionamiento de las necesidades del almacenamiento futuro, no están soportadas debidamente por datos y pronósticos precisos, por el contrario, se suelen hacer simplificaciones

basadas en supuestos y percepciones personales”. Esta situación lleva a las empresas a disponer de un almacén con espacio sin utilizar o insuficiente al corto plazo, lo que incurre en más gastos operativos.

Un pronóstico consiste en predecir un evento futuro (Anderson, Sweeney y Williams, 2008). No obstante, acertar es difícil y más aún acertar con frecuencia, por esta razón los administradores deben asumir que no existen pronósticos perfectos, sin importar la técnica que usen. Además, no hay que subestimar su efectividad, ya que los resultados que se obtengan (reducción/aumento de pérdidas/costos) dependerán de la profundidad del análisis que se haga de ellos.

Esta investigación contribuye con herramientas de pronósticos que asistirán al administrador de la PYME en estudio a anticipar la demanda para tomar decisiones de compra más acertadas que optimicen los niveles de inventario.

Para lograr el objetivo planteado se abordan 4 apartados. Primero se describen las prácticas de predicción observadas en PYMES del sector ferretero del Estado de Tlaxcala y las técnicas de pronósticos usualmente aplicadas y enseñadas en la academia. En segundo lugar, se detalla el diseño experimental y los resultados obtenidos. Por último, se presentan los hallazgos y conclusiones.

En su aplicación se utilizaron los datos históricos de venta del cemento gris de una empresa de compra/venta de materiales de construcción en el Estado de Tlaxcala. La elección del cemento como producto de estudio se sustenta en su aportación al 50% de las utilidades globales de la empresa (resultado de un Análisis ABC multicriterio).

## 2. Revisión de la literatura

### 2.1 Uso de la predicción en las PYMES

A pesar del gran avance de la ciencia en los temas de predicción, muchas PYMES continúan planeando su inventario al “tanteo”, limitando su crecimiento a la experiencia del administrador. Una de las barreras es el desconocimiento de las herramientas existentes (Beltrán, 2006). Aunque actualmente existen miles de opciones en Tecnologías de la Información (TICs) que ofrecen este servicio, su adquisición requiere de capital y liquidez que muchos no tienen. Un estudio en Estados Unidos sobre el uso del software para pronosticar, reportó que sólo el 10.8% de las empresas evaluadas usa el software comercial (Acosta, Díaz y Anaya, 2009).

En la presente investigación se comparan los resultados obtenidos en las siguientes prácticas observadas en el entorno local del sector:

- Promedio semanal de las últimas 52 observaciones
- Promedio semanal del mes anterior
- Misma cantidad que la semana anterior

Su inclusión en el análisis comparativo permite ilustrar claramente la brecha entre las técnicas científicas en relación a las prácticas simples.

### 2.2 Técnicas de pronósticos en la literatura

Existen varias investigaciones que hablan de la predicción de la demanda y sus beneficios. Murillo, Trejos y Carvajal (2003) aplican ARIMA para pronosticar la demanda de energía eléctrica utilizando los datos de consumo de un año de una provincia colombiana para entrenar el modelo -divididos en 24 series con 365 observaciones para cada hora del día-.

Méndez y López (2014) comparan los métodos de suavización exponencial simple y promedio móvil doble para pronosticar la demanda en un ambiente de alta variabilidad. En esta investigación utilizan los pronósticos con el objetivo de reducir el inventario mínimo de 30 días de demanda a solo 25. Esto con el objetivo de reducir el costo de almacenaje sin perder el nivel de servicio.

Contreras, Atziry, Martínez y Sánchez (2016) comparan cuatro métodos para pronosticar la demanda de almacenamiento de productos perecederos, utilizando un conjunto de datos de 52 observaciones semanales para pronosticar las 4 semanas siguientes. Los modelos seleccionados fueron: suavización exponencial, suavización exponencial ajustada, promedios móviles y promedios móviles ponderados.

Tobón, J. (2020) utiliza la metodología ARIMA para pronosticar la demanda de estudiantes de pregrado de una universidad, manejando 36 observaciones semestrales para alimentar el modelo. Su investigación concluye que el modelo requiere de más datos.

Orlando, Rivas, Pérez y Marrero (2017) realizan el pronóstico de la demanda de medicamentos para una empresa farmacéutica, para lo cual utilizaron redes neuronales artificiales y observaciones mensuales correspondientes a 7 años y 5 variables independientes.

Para esta investigación se eligieron las siguientes técnicas de pronósticos:

- Regresión lineal simple y suavización exponencial simple, por ser dos técnicas ampliamente estudiadas y enseñadas en la academia.
- Regresión no lineal (logarítmica natural), por obtener resultados favorables en un experimento preliminar.
- Regresión por redes neuronales, por sus posibilidades de pronóstico observadas en Orlando et al. (2017).
- Metodología Box-Jenkins, por su amplia aplicación en el estado del arte.

#### Regresión lineal simple

Consiste en modelar -de manera lineal- la relación entre una variable dependiente y una única variable independiente (Laguna, 2014). El método utiliza funciones de predicción lineal que operan a través del ajuste de coeficientes utilizando observaciones de entrenamiento. Este método ha sido utilizado extensamente en aplicaciones prácticas (Yan, X., 2009). La Ecuación 1 describe el modelo de regresión lineal simple.

$$y = \beta_0 + \beta_1 x \quad (1)$$

Donde  $y$  es el valor esperado para un valor dado de  $x$ .  $\beta_0$  y  $\beta_1$  son los parámetros del modelo.  $\beta_0$  denota la intersección de la recta con el eje  $y$  (el valor de  $y$  cuando  $x=0$ ) y  $\beta_1$  la pendiente de la línea (el cambio

promedio en y resultante de un aumento de una unidad en x). El error # es una variable aleatoria que representa la desviación de la línea recta.

#### Suavización exponencial

Técnica de pronóstico que suaviza la serie de tiempo promediando ponderadamente los valores históricos. Las ponderaciones decrecen exponencialmente a medida que los datos se vuelven más antiguos (Guerra, Sánchez y Reyes, 1997). Es decir, cuanto más reciente sea la observación, mayor será el peso asociado.

Este método es adecuado para pronosticar datos que no muestran claramente algún comportamiento de tendencia o estacionalidad (Hyndman y Athanasopoulos, 2018). La Ecuación 2 describe el modelo de suavización exponencial simple.

$$y_t = \alpha Y_{(t-1)} + (1-\alpha) y_{(t-1)} \quad (2)$$

Donde  $y_t$  es el valor estimado de la variable en el tiempo  $t$ ,  $\alpha$  es la constante de suavización o coeficiente de ponderación (un número entre 0 y 1),  $Y_{(t-1)}$  es el valor real de la variable en el periodo anterior a pronosticar  $(t-1)$  y  $y_{(t-1)}$  corresponde al valor estimado previo.

#### Regresión no lineal

En muchos casos, una función no lineal es más adecuada para modelar una determinada serie de datos. La regresión no lineal es una forma de análisis de regresión donde la relación entre las variables presenta cierto grado de curvatura (Cole, 2002) y las predicciones se generan estimando los parámetros de una función no lineal (Rivas, López y Velasco, 1993).

La forma más sencilla de modelar una relación no lineal es transformar la variable dependiente y y/o la variable independiente x antes de estimar un modelo de regresión. Sin embargo, el modelo sigue siendo lineal en los parámetros (Hyndman et al, 2018).

La transformación de datos tiene como objetivo simplificar los patrones en los datos históricos para generar pronósticos más precisos. Limpian y preparan los datos para su análisis estadístico eliminando las fuentes conocidas de variación o haciendo que el patrón sea más consistente en todo el conjunto de datos (Hyndman et al, 2018 y Osborne, 2010). Una de las transformaciones matemáticas tradicionales más utilizada es el logaritmo -base 10 o natural-. En el caso práctico se selecciona una función logarítmica natural. La ecuación 3 describe la línea de regresión logarítmica natural utilizada.

$$y = a + b \ln(x) \quad (3)$$

Donde y es el valor futuro estimado, x es la variable independiente, a y b son los parámetros del modelo y  $\ln(x)$  es el logaritmo natural de la variable independiente.

#### Regresión por redes neuronales

Las redes neuronales permiten capturar las relaciones entre variables independientes en un esquema que estima cualquier función continua (aunque no sea lineal). La red neuronal tiene un conjunto de nodos de entrada (input layer) que usualmente se alimenta de las variables independientes. Estas entradas se combinan a través de varias capas ocultas (hidden layers) las cuales detectan todas las posibles correlaciones entre las diferentes entradas y la salida. El nodo de salida usualmente es el



que se encarga de regresar el valor pronosticado (output layer). La Figura 1 muestra un ejemplo de estructura de una red neuronal multicapa.




Figura 1: Representación interna de una red neuronal

Fuente: Elaboración propia.

Si una red neuronal tiene una sola entrada y una sola salida, el modelo será altamente similar a una regresión lineal con las siguientes diferencias:

- El cálculo es más lento y podría requerir mayor tiempo para generar una predicción correcta.
- El modelo es aleatorio por lo que, en ocasiones, podría no regresar una predicción correcta.
- El modelo se vuelve mucho más poderoso entre más y mejores variables independientes se conecten a la capa de entrada.
- El modelo puede pronosticar funciones que no sigan patrones simples.

Perceptrón Multicapa (Multi-Layer Perceptron o MLP por sus siglas en inglés) es el modelo de red neuronal artificial más utilizado en la resolución de problemas de regresión (Flórez y Fernández, 2008). Su arquitectura neuronal se diferencia por incluir una o varias capas ocultas que vinculan los nodos de entrada con los nodos de salida.

Este tipo de red neuronal es un modelo neuronal de alimentación/propagación hacia adelante (Flórez y Fernández, 2008; McLeod, 2000; Velásquez, 2004). Esto significa que el flujo de datos fluye en un sólo sentido -de la capa de entrada hacia la capa de salida-, sin realimentación de las neuronas.

La regresión por redes neuronales utilizada se sustenta en el modelo Perceptrón Multicapa. La estructura de la red aplicada se caracteriza por tener una capa de entrada de 52 nodos, 100 capas ocultas y un solo nodo de salida, utilizándose los parámetros por default de la librería Scikit-learn para Python (función de activación ReLU y  $\alpha=0.0001$ ).

#### Metodología Box-Jenkins

Este modelo se enfoca en describir las autocorrelaciones de los datos y tiene la capacidad de operar en series de tiempo estacionarias y no estacionarias (Hanke y Wichern, 2010; Hyndman et al, 2018). Una serie de tiempo estacionaria es aquella cuyas propiedades no dependen del momento en que se observa la serie -libre de tendencia y estacionalidad-.

Por el contrario, una serie de tiempo no estacionaria exhibe patrones de tendencia y/o estacionalidad.

La prueba de Dickey-Fuller permite verificar si la serie es o no estacionaria. Cuando la serie resulta ser no estacionaria, ésta debe transformarse a estacionaria por simple diferenciación de los datos (Jara, 1998).

La metodología Box-Jenkins se describe en términos de los parámetros estructurales  $p$ ,  $d$  y  $q$ , utilizando la notación general  $ARIMA(p,d,q)$ . Estos parámetros representan el orden del componente autorregresivo - $p$ -, el grado de diferenciación para la estacionariedad - $d$ - y el orden del componente de media móvil - $q$ - (Arnau, 2001). Su aplicación requiere de series temporales conformadas por al menos 50 registros (Jara, 1998).

La serie de datos manejada en esta investigación sigue un comportamiento estacionario, siendo el mejor modelo estimado  $ARIMA(0,0,1)$ , también denotado por  $MA(1)$ .

### 2.3 Sobreajuste y desajuste

Cuando se entrena un modelo con un conjunto de datos se espera que éste sea capaz de generalizar correctamente el comportamiento de los datos. Sin embargo, encontrar el equilibrio en su aprendizaje es una tarea difícil. Gu, Wylie, Boyte, Picotte, Howard, Smith y Nelson (2016) mencionan que el uso inapropiado de los datos de muestra -porcentaje de datos usados en el entrenamiento y pruebas del modelo- pueden causar efectos de sobreajuste (overfitting) o desajuste (underfitting).

El sobreajuste se presenta cuando el modelo en un momento determinado durante el período de entrenamiento, no mejora su capacidad para resolver más problemas (Khalaf y Zaman, 2015). El modelo es demasiado específico y sólo genera el comportamiento del conjunto de entrenamiento (van der Aalst, Rubin, van Dongen, Kindler y Günther, 2006), por lo que es poco probable generar una buena predicción sobre patrones nunca antes vistos. La Figura 2 muestra un ejemplo de sobreajuste, la línea azul es capaz de acertar correctamente los datos de muestra, pero el modelo será incapaz de generar una buena predicción con nuevos datos.






Figura 2: Sobreajuste

Fuente: Elaboración propia.

El desajuste se presenta cuando el modelo es incapaz de capturar la variabilidad de los datos, resultado de utilizar un modelo demasiado simple para describir la dinámica de los datos (Khalaf et al, 2015). El modelo es demasiado general y genera un comportamiento poco probable (van der Aalst et al, 2006). La Figura 3 muestra un ejemplo de desajuste, la línea azul es incapaz de seguir el comportamiento variable de los datos de muestra.




Figura 3: Desajuste

Fuente: Elaboración propia.

### 3. Diseño experimental

La investigación realizada es de tipo aplicada, cuantitativa, descriptiva y transversal. Se aplicaron diversas técnicas de pronósticos cuantitativas para un mismo producto (cemento gris), basadas en el análisis de datos de

venta históricos, con el fin de evitar limitar el estudio a un sólo modelo de comportamiento, que puede o no representar la realidad de la demanda.

En un estudio preliminar se utilizaron los datos de venta mensuales de 2014 a 2018 de 5 sucursales para estimar la demanda anual del cemento con 5 técnicas diferentes. Rodríguez (2013) afirma que los pronósticos a menor plazo generan resultados más precisos, por esta razón, las 3 mejores técnicas resultantes del estudio preliminar, se analizan con un horizonte de planeación semanal y el criterio de decisión empleado para la selección se basa en el error real en unidades, por presentar mayor asertividad con las condiciones internas de la empresa (tamaño de la bodega, condiciones de pedido, etc.). La Tabla 1 lista el error real promedio de cada técnica de pronóstico utilizada en el estudio preliminar.

| <b>Técnicas de pronóstico</b> | <b>Error</b> |
|-------------------------------|--------------|
| Regresión lineal simple       | 15,749       |
| Suavización exponencial*      | 19,525       |
| Regresión logarítmica natural | 26,501       |
| Método Holt-Winters           | 26,986       |
| Regresión cuadrática          | 47,200       |

Tabla 1: Error real promedio reportado para el pronóstico de 2019

Fuente: Elaboración propia a partir de resultados de Minitab 17.

\*Método aplicado para diferentes valores de alfa, con resultados significativos en  $\alpha=0.2$ .

El diseño experimental se basa en el propuesto por Contreras et al. (2016): se utilizan 52 semanas como datos de entrenamiento y se pronostican las semanas de marzo y abril de 2020 (4 semanas adicionales a la investigación citada), realizando así una mayor cantidad de pruebas. Entonces, los datos de venta recopilados comprenden las semanas de marzo de 2019 a abril de 2020, siendo las especificaciones para cada modelo:

- Promedio semanal del último año, regresión lineal simple, regresión no lineal, regresión por redes neuronales y metodología Box-Jenkins comprenden las últimas 52 observaciones previas a la semana a pronosticar.
- Promedio semanal del último mes considera las últimas 4 observaciones previas a la semana a pronosticar.
- Semana anterior utiliza la observación inmediata anterior a la semana a pronosticar.

Los resultados se reportan con 3 indicadores:

- Error real. Valor absoluto resultado de la diferencia entre el pronóstico y la demanda real observada.
- Faltantes. Cantidad de unidades pronosticada por debajo de la demanda real observada.

- Sobrantes. Cantidad de unidades pronosticada por arriba de la demanda real observada.

El error en términos de faltantes es crucial en situaciones donde los proveedores no pueden efectuar entregas inesperadas de forma inmediata, derivando en pérdida de ventas y clientes por producto insuficiente. Ahora bien, el error en sobrantes es importante por los costos de almacenamiento que representan y cuando existe poca disponibilidad de espacio en bodega.

#### 4. Resultados

##### 4.1 Análisis del comportamiento de la demanda

Peterson y Silver (1985) propusieron el coeficiente de variabilidad (CV) como medida útil para determinar la naturaleza de la demanda (constante o irregular). Taha (2012) señala que la demanda tiene un comportamiento errático con un CV mayor a 20% y constante con un CV menor a 20%. Considerando esta premisa, el cemento presenta una demanda irregular, al estimarse su valor en 20.67%. La Figura 4 ilustra el comportamiento de la demanda desde marzo de 2019 a abril de 2020.




Figura 4: Comportamiento de la demanda semanal de cemen

Fuente: Elaboración propia

Adicionalmente, se aplicó la prueba Shapiro-Wilk con distribución asimétrica positiva. Esto con el fin de confirmar la forma de distribución de los datos y así, explicar mejor el comportamiento de la demanda. Se registraron las siguientes observaciones:

- La media, mediana y desviación estándar son de 6902, 6906 y 1483 bultos, respectivamente.
- El valor del coeficiente de asimetría de Fisher (0.41) responde a una distribución asimétrica positiva o a la derecha -Véase Figura 5-.
- La prueba Shapiro-Wilk genera un valor p-value de 0.196, demostrando que los datos siguen una distribución normal.
- La demanda sigue un patrón no lineal y es altamente variable.




Figura 5: Histograma\* de la demanda de cemento

Fuente: Elaboración propia

Esto implica que la demanda cambia manteniendo siempre valores cercanos a la media, pese a su comportamiento errático.

#### 4.2 4.2 Análisis comparativo de los pronósticos

El criterio de selección de las técnicas de pronósticos se basa en el valor del error del pronóstico. Las Tablas 2 y 3 muestran los errores promedio de los pronósticos de marzo y abril de 2020, notándose lo siguiente:

- El promedio semanal del último mes y la demanda de la semana anterior generan pronósticos nada confiables. El primero es muy inconsistente, en marzo se coloca como una de las técnicas con peores resultados y en abril entre las tres mejores. El segundo obtiene siempre pronósticos malos, ubicándose entre las dos peores técnicas.
- El promedio semanal del último año es el más estable de las prácticas simples, debido a que los datos siguen una distribución normal.
- La regresión no lineal es la técnica que obtuvo mejores resultados en el experimento, aunque por una diferencia mínima.
- La regresión lineal simple presenta resultados menos favorables que la regresión logarítmica natural, probablemente por la clara no linealidad de los datos observada en la Figura 4.
- La suavización exponencial simple, para esta investigación no resulta un buen método debido a que sus pronósticos se encuentran entre los tres peores resultados, a diferencia de en Méndez y López (2014).
- El modelo de regresión por redes neuronales (Perceptrón Multicapa) genera resultados inferiores al resto de las técnicas científicas probadas. Situación que puede deberse a la necesidad de utilizar más observaciones y/o más variables independientes.
- La metodología Box-Jenkins se ubica entre las cuatro mejores técnicas evaluadas, superando los resultados de la regresión por redes neuronales (en 100 bultos mínimo) porque sus predicciones se alejan en menor medida del valor real.

| Técnicas de pronóstico           | Error        | Faltantes  | Sobrantes  |
|----------------------------------|--------------|------------|------------|
| Promedio semanal del último año* | 1,022        | 627        | 2,204      |
| Promedio semanal del último mes* | 1,703        | 1,990      | <b>844</b> |
| Semana inmediata anterior*       | 1,908        | 1,874      | 1,942      |
| Regresión lineal simple*         | 1,203        | 968        | 1,907      |
| Suavización exponencial simple*  | 1,304        | 1,196      | 1,628      |
| <b>Regresión no lineal*</b>      | <b>1,008</b> | <b>615</b> | 2,187      |
| Regresión por redes neuronales** | 1,302        | 1,215      | 1,562      |
| Metodología Box-Jenkins**        | 1,185        | 1,133      | 1,237      |

Tabla 2. Error promedio del pronóstico de marzo 2020

Fuente. Elaboración propia a partir de resultados de \*Excel y \*\*Python. Los números en negrita hacen referencia a las técnicas que generaron el menor error real, de faltantes y de sobrantes.

El Anexo 1 muestra los resultados detallados del mes de marzo

| Técnicas de pronóstico           | Error | Faltantes  | Sobrantes |
|----------------------------------|-------|------------|-----------|
| Promedio semanal del último año* | 589   | 305        | 873       |
| Promedio semanal del último mes* | 569   | <b>149</b> | 989       |

Tabla 3: Continuación.

| Técnicas de pronóstico           | Error      | Faltantes | Sobrantes  |
|----------------------------------|------------|-----------|------------|
| Semana inmediata anterior*       | 767        | 686       | 793        |
| Regresión lineal simple*         | 569        | 721       | <b>417</b> |
| Suavización exponencial simple*  | 617        | 477       | 757        |
| <b>Regresión no lineal*</b>      | <b>568</b> | 332       | 804        |
| Regresión por redes neuronales** | 774        | 933       | 615        |
| Metodología Box-Jenkins**        | 599        | 328       | 869        |

Tabla 3. Error promedio del pronóstico de abril 2020

Fuente. Elaboración propia a partir de resultados de \*Excel y \*\*Python. Los números en negrita hacen referencia a las técnicas que generaron el menor error real, de faltantes y de sobrantes.

El Anexo 2 muestra los resultados detallados del mes de abril.

Las Figuras 6 y 7 ilustran el comportamiento de la demanda real versus las técnicas seleccionadas. Estas gráficas lineales se crearon con la finalidad de comprender de manera simple el comportamiento de las técnicas de pronósticos, observándose que:

- Ninguna técnica exhibe un pronóstico acertado al de la demanda real.
- Los mejores resultados se observaron con modelos lineales o casi lineales (promedio semanal del último año, regresión lineal y regresión no lineal). Sin embargo, estos modelos son incapaces de capturar la variabilidad de los datos, generando efectos de desajuste.
- El método de redes neuronales y la metodología Box-Jenkins exhiben un patrón de cambio más evidente en la tendencia del consumo (incrementos y decrementos). No obstante, el Perceptrón Multicapa tiene mejor capacidad que el ARIMA para predecir la tendencia del consumo (75% y 25% de aciertos, respectivamente). Las fallas observadas en el método de redes neuronales se presentaron ante cambios bruscos

en los datos de entrada, por lo que se recomienda profundizar su entrenamiento con más variables independientes y observaciones.




Figura 6: Gráfica de líneas de la demanda real vs los pronósticos comúnmente aplicados en las PYMES locales

Fuente: Elaboración propia




Figura 7: Gráfica de líneas de la demanda real vs los pronósticos elegidos de la literatura

Fuente: Elaboración propia

En la Figura 6 se observa que de las técnicas locales, el promedio semanal del último año es la que exhibe notoriamente un comportamiento casi lineal. Esta particularidad de su línea de tendencia le permitió generar resultados aceptables -a diferencia del resto- por la distribución normal de los datos. Caso contrario ocurre con la semana inmediata anterior, el cual pese a mostrar un patrón de cambio más evidente obtiene el peor resultado por sus proyecciones constantes en dirección contraria a la tendencia real.

Sucede algo similar con las técnicas de la literatura. Aquellas que tienen un comportamiento lineal o casi lineal generan mejores resultados, como la regresión no lineal y la regresión lineal simple -Véase Figura 7-.

Pero existe una excepción. La metodología Box-Jenkins obtiene buenos resultados en términos de error real -se debate entre el segundo y tercer lugar- y aunque refleja gráficamente patrones de cambio, no tiene la capacidad de predecir la tendencia de la demanda.



En este diseño experimental la regresión no lineal es el modelo que mejor se ajusta a la serie de datos por el comportamiento variable de la demanda, la distribución normal de los datos y su mayor asertividad en la tendencia del consumo. No obstante, el promedio semanal del último año es la mejor alternativa cuando no se dispone del tiempo, conocimiento y/o acceso a alguna técnica de regresión.

#### 5. Discusión de resultados

La presente investigación se desarrolla en una empresa de compra-venta de materiales de construcción en el Estado de Tlaxcala y busca contribuir con herramientas de pronósticos que asistan al administrador a anticipar las ventas futuras para tomar decisiones de compra más acertadas que optimicen los niveles de inventario.

Los resultados obtenidos revelan pronósticos acertados en el patrón de tendencia de la demanda: 88% de ocurrencias en la regresión no lineal y 75% de ocurrencias en la regresión por redes neuronales. Ciertamente, las fallas en este último método ocurrieron a causa de un cambio brusco en el valor de los datos de entrenamiento.

Conocer la tendencia futura puede ser realmente útil y aplicable en diversos sectores y ámbitos, como salud, economía y finanzas, entre otros. Específicamente, el conocimiento oportuno de las alzas o bajas en el consumo de un producto le permitirá al administrador de la PYME reaccionar a priori en la planificación de las compras estableciendo dónde invertir y ajustando la cantidad a pedir, en la planeación de las ventas dirigiendo los esfuerzos hacia los productos adecuados y en la planeación del inventario determinando qué productos y en qué cantidad mantener en el almacén; reduciendo así los faltantes o sobrantes y optimizando el nivel de servicio al cliente (Arango, Giraldo y Castrillón, 2013).

Considerando que el conjunto de datos corresponde a una distribución normal, cualquier pronóstico cercano o igual a la media resultará aceptable. Esto explica por qué los modelos lineales o casi lineales obtienen los mejores resultados. Excepto por la Metodología Box-Jenkins que exhibe patrones de cambio evidentes y genera buenos resultados en términos de error. Sin embargo, se caracterizó por su baja capacidad para predecir la tendencia del consumo (25% de aciertos).

Una observación interesante son los resultados superiores del ARIMA frente a la regresión por redes neuronales, modelo que predijo el 75% de veces la tendencia. Este comportamiento se debe a que aunque el ARIMA proyecta continuamente la tendencia en sentido contrario a la real, la desviación entre el valor pronosticado y el valor real era menos significativo.

Bajo esta óptica, la regresión no lineal resultó ser la mejor técnica porque sus resultados oscilan en dirección correcta a la demanda y con valores cercanos a la media, al mismo tiempo que la naturaleza errática de la demanda provoca que los datos se ajusten mejor a un modelo no lineal.

El uso prudente de las técnicas de pronósticos complementa el juicio personal y la habilidad directiva del administrador al sustentar las conjeturas futuras con información. Por este motivo, se sugiere hacer un estudio comparativo de distintas técnicas de pronósticos sobre el mismo

problema para evitar caer en el error de limitarse a un solo modelo que puede no representar correctamente el comportamiento de los datos, ya que su imprecisión puede llevar a malas decisiones.

## 6. Conclusiones y recomendaciones

El uso y aplicación correcta de los pronósticos en la toma de decisiones de los empresarios de las PYMES es de interés porque representa una iniciativa hacia la competitividad a través del fortalecimiento de las habilidades del administrador. No olvidar que las PYMES operan en un entorno cambiante y lleno de incertidumbre, y pronosticar la demanda adecuadamente le permitirá al administrador estar un paso adelante y tomar decisiones más acertadas en la planeación del inventario, ventas y compras, áreas vitales en cualquier empresa.

La elección correcta de la técnica de pronóstico es fundamental en la planificación. Elegir al azar y confiar que den resultados acertados es ciertamente equivocado, porque no existe un modelo ideal generalizable a todas las problemáticas. Por esta razón, en la investigación se realiza un análisis comparativo de técnicas de pronósticos utilizadas comúnmente en el sector local y en la literatura, ilustrando su comportamiento con datos históricos de venta del cemento de una empresa de compra-venta de materiales de construcción.

Los modelos se retroalimentaron en cada prueba, es decir, al calcular un nuevo pronóstico se agregaba el nuevo dato de demanda y se eliminaba la observación más antigua. Esta acción permitió la continua actualización del modelo y la generación de pronósticos menos imprecisos.

Se halló que la técnica de regresión logarítmica natural genera mejores resultados (menor error promedio, 88% de aciertos en la tendencia del consumo y error en sobrantes aceptable en términos de las capacidades del almacén). Sin embargo, un análisis gráfico reveló efectos de desajuste en el modelo, esto es a causa de su simplicidad que no le permite describir la naturaleza errática de los datos. Aunque podría no ser recomendable continuar investigando con esta técnica en específico, sería interesante realizar pruebas sobre su capacidad para predecir la tendencia y explorar con otros modelos no lineales.

Asimismo, se descubrió que si los datos presentan una distribución normal, el promedio como técnica de pronóstico es una buena opción cuando no se dispone de tiempo, ya que sus resultados son cercanamente eficientes a la regresión lineal simple y la regresión logarítmica natural, además de que se evita el uso de cálculos elaborados.

Si bien la regresión por redes neuronales (Perceptrón Multicapa) no produjo resultados satisfactorios, presenta la capacidad de reflejar un comportamiento variable evidente (observable gráficamente). Se tiene la hipótesis que de entrenarse adecuadamente podría exitosamente pronosticar demandas que son altamente variables. Por esta razón, se pretende continuar con la investigación utilizando y combinando otras variables de decisión, mayor cantidad de pruebas y datos.

Finalmente, se recomienda el uso de los pronósticos primordialmente en los productos más importantes de la empresa con el fin de generar un impacto a mayor escala en la reducción de costos de inventario,

eligiéndose la técnica adecuada para cada producto mediante un análisis comparativo previo.

#### Agradecimientos

Se agradece al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca de posgrado, No. 904826, otorgada al primer autor.

## 7. Bibliografía

- Acosta, M., Díaz, R. y Anaya, A. (2009). Revisión de técnicas de análisis de decisión multicriterio (multiple criteria decision analysis–MCDA) como soporte a problemas complejos: pronósticos de demanda. *Revista Guillermo de Ockham*, 7(2), 91-110. Disponible en: <http://www.revistas.usb.edu.co/index.php/GuillermoOckham/article/view/547/349> Consultado el 07/06/2020.
- Agudelo, D. y López, Y. (2018). Dinámica de sistemas en la gestión de inventarios. *Ingenierías USBMed*, 9(1), 75-85. Disponible en: <http://www.revistas.usb.edu.co/index.php/IngUSBmed/article/view/3305/2782> Consultado el 15/06/2020.
- Aguirre, R. y Armenta C. (2012). La importancia del control interno en las pequeñas y medianas empresas en México. *Revista El Buzón de Pacioli*, 12(76), 1-17. Disponible en: [https://www.itson.mx/publicaciones/pacioli/Documents/no77/68d\\_-\\_la\\_importancia\\_del\\_contorl\\_interno\\_en\\_las\\_pequenas\\_y\\_medianas\\_empresas\\_en\\_m](https://www.itson.mx/publicaciones/pacioli/Documents/no77/68d_-_la_importancia_del_contorl_interno_en_las_pequenas_y_medianas_empresas_en_m) Consultado el 10/11/2020.
- Anderson, D., Sweeney, D. y Williams, T. (2008). Estadística para Administración y Economía. [Traducido al español de Statistics for Business and Economics]. 10ª edición. México: Cengage Learning.
- Arango, J., Giraldo, J. y Castrillón, O. (2013). Gestión de compras e inventarios a partir de pronósticos Holt-Winters y diferenciación de nivel de servicio por clasificación ABC. *Scientia et technica*, 18(4), 743-747. Disponible en: <https://revistas.utp.edu.co/index.php/revistaciencia/article/viewFile/7171/5623> Consultado el 15/06/2020.
- Arnau, J. (2001). Diseños de Series Temporales: Técnicas de Análisis. Barcelona: Edicions de la Universitat de Barcelona.
- Beltrán, A. (2006). Los 20 problemas de la pequeña y mediana empresa. *Sotavento MBA*, (7), 8-15. Disponible en: <https://revistas.uexternado.edu.co/index.php/sotavento/article/view/1574/1426> Consultado el 05/06/2020.
- Cleri, C. (2013). El Libro de las PyMEs. 1ª edición. Buenos Aires: Ediciones Granica.
- Cole, J. (2002). Nociones de Regresión Lineal. Universidad Francisco Marroquin. Octllbre. Disponible en: <http://fce2.ufm.edu/jhcole/regresion.pdf> Consultado el 10/06/2020.
- Contreras, A., Atzir, C., Martínez, J. y Sánchez, D. (2016). Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. *Estudios Gerenciales*, 32(141), 387-396. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0123592316300754> Consultado el 16/05/2020.

- Cruz, A. (2017). UF0476: Gestión de inventarios. COML0210-Gestión y control del aprovisionamiento. 1ª edición. México: IC Editorial.
- de la Garza, M., Zavala, M., López, J. y López, P. (2019). Inventario de las causas del fracaso en emprendedores sociales en México (CAFES-M). *Revista Perspectivas*, (43), 107-134. Disponible en: [http://www.scielo.org/bo/pdf/rp/n43/n43\\_a05.pdf](http://www.scielo.org/bo/pdf/rp/n43/n43_a05.pdf) Consultado el 07/06/2020.
- Eppen, G., Gould, F., Schmidt, C., Moore, J. y Weatherford, L. (2000). *Investigación de Operaciones en la Ciencia Administrativa*. [Traducido al español de *Introductory Management Science*]. 5ª edición. México: Prentice-Hall.
- Flórez, R. y Fernández, J. (2008). *Las Redes Neuronales Artificiales: Fundamentos Teóricos y Aplicaciones Prácticas*. 1ª edición. España: Netbiblo.
- García, O. y Nava, R. (2019). Características del dueño-administrador en la innovación y desempeño de pequeñas y medianas empresas metalmeccánicas del Valle de Toluca. *RECAI: Revista de Estudios en Contaduría, Administración e Informática*, 8(23), 39-62. Disponible en: <https://recai.uaemex.mx/article/view/12860/10150> Consultado el 30/05/2020.
- Gu, Y., Wylie, B., Boyte, S., Picotte, J., Howard, D., Smith, K. y Nelson, K. (2016). An optimal sample data usage strategy to minimize overfitting and underfitting effects in regression tree models based on remotely-sensed data. *Remote Sensing*, 8(11), 943-953. Disponible en: <https://www.mdpi.com/2072-4292/8/11/943/htm> Consultado el: 10/08/2020.
- Guerra, J., Sánchez, G. y Reyes, B. (1997). Modelos de series de tiempo para predecir la inflación en Venezuela. Banco Central de Venezuela, Gerencia de Investigaciones Económicas, 1-30. Disponible en: <http://200.74.197.130/Upload/Publicaciones/doc13.pdf> Consultado el 14/06/2020.
- Hanke, J. y Wichern, D. (2006). *Pronósticos en los Negocios*. [Traducido al español de *Business forecasting*]. 8ª edición. México: Pearson Educación.
- Hernández, L. (2007). Competencias esenciales y PYMEs familiares: Un modelo para el éxito empresarial. *Revista de Ciencias Sociales (Ve)*, 13(2), 249-263. Disponible en: <https://www.redalyc.org/pdf/280/28011677005.pdf> Consultado el 10/11/2020.
- Hyndman, R. y Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*, 2ª edición. Australia: OTexts.
- INEGI (2020). Comunicado de Prensa Núm. 285/20. México: INEGI. Disponible en: <https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2020/MYPIMES20.pdf> Consultado el 13/11/2020.
- Jara, M. (1998). *Las series temporales: aplicación de los modelos ARIMA para el análisis de la sintomatología del ciclo menstrual*. (Trabajo de grado). Barcelona: Micromagna.
- Khalaf, H. y Zaman, R. (2015). Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices*, 1, 163-172. Disponible en: [https://www.researchgate.net/profile/Haider\\_Allamy/publication/295198699\\_METHODS\\_TO\\_AVOID\\_OVER-FITTING\\_AND\\_UNDER-](https://www.researchgate.net/profile/Haider_Allamy/publication/295198699_METHODS_TO_AVOID_OVER-FITTING_AND_UNDER-)

- FITTING\_IN\_SUPERVISED\_MACHINE\_LEARNING\_COMPARATIVE\_STU  
links/56c8253f08aee3cee53a3707.pdf Consultado el: 11/08/2020.
- Laguna, C. (2014). Correlación y regresión lineal. Instituto Aragonés de Ciencias de la Salud, 1-18. Disponible en: <http://www.ics-aragon.com/cursos/salud-publica/2014/pdf/M2T04.pdf> Consultado el 10/06/2020.
- Martínez, J. (2010). Empresas Familiares, Reto al Destino: Claves para Perdurar con Éxito. 1ª edición. Buenos Aires: Granica.
- Méndez, G. y López, E. (2014). Metodología para el pronóstico de la demanda en ambientes multiproducto y de alta variabilidad. *Tecnura*, 18(40), 89-102. Disponible en: <https://revistas.udistrital.edu.co/index.php/Tecnura/article/view/6977/8655> Consultado el 15/05/2020.
- Muñoz, A. (2014). Metodología para el dimensionamiento de almacenes basado en la estimación de la demanda para el sector cosmético. (Trabajo de grado). Universidad Milinar Nueva Granada. Disponible en: <https://repository.unimilitar.edu.co/bitstream/handle/10654/12624/ART%C3%8DCULO%20FINAL.pdf?sequence=1> Consultado el 17/05/2020.
- Murillo, J., Trejos, A. y Carvajal, P. (2003). Estudio del pronóstico de la demanda de energía eléctrica, utilizando modelos de series de tiempo. *Scientia et technica*, 3(23), 37-42. Disponible en: <http://revistas.utp.edu.co/index.php/revistaciencia/article/view/7379/4403> Consultado el 20/05/2020.
- Orlando, Y., Rivas, A., Pérez, M. y Marrero, F. (2017). Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, 23(1), 1-18. Disponible en: <https://www.redalyc.org/pdf/1815/181549596004.pdf> Consultado el 22/05/2020.
- Osborne, J. (2010). Improving your data transformations: Applying the Box-Cox transformation. *Practical Assessment, Research, and Evaluation*, 15(12), 1-9. Disponible en: <https://scholarworks.umass.edu/cgi/viewcontent.cgi?article=1238&context=pare> Consultado el 19/11/2020.
- Peterson, R. y Silver, E. (1985). *Decision Systems for Inventory Management and Production Planning*. New York: John Wiley & Sons Inc.
- Rivas, G., López, L. y Velasco, A. (1993). Regresión no lineal. *Revista Colombiana de Estadística*, 14(27), 89-102. Disponible en: <https://revistas.unal.edu.co/index.php/estad/article/viewFile/10003/10531> Consultado el 10/06/2020.
- Rodríguez, A. (2013). Modelo de planeación de mano de obra y materiales con demanda variable de envases farmacéuticos y cosméticos plásticos. *Gerencia en Logística Integral*, 1, 1-19. Disponible en: <https://repository.unimilitar.edu.co/bitstream/handle/10654/11009/MODELO%20DE%20PLANEACI%C3%93N%20DE%20MANO%20DE%20OBRA%20Y%20MATERIALES%20AR.pdf?sequence=1&isAllowed=y> Consultado el 16/06/2020
- Roscoe, K. y Mckeown, P. (1986). *Modelos Cuantitativos para Administración*. México: Iberoamérica.
- Sturges, H. (1926). The choice of a class interval. *Journal of the American Statistical Association*, 21(153), 65-66. Disponible en: <http://www.esalq.usp.br/departamentos/lce/arquivos/aulas/2013/LCE0216/Sturges1926.pdf> Consultado el 13/06/2020.

- Taha, H. (2012). Investigación de Operaciones. [Traducido al español de Operations Research: An Introduction]. 9ª edición. México: Pearson Educación. Disponible en: [https://www.academia.edu/23181259/Investigacion\\_de\\_operaciones\\_9na\\_Edicion\\_Hamdy\\_A\\_Taha\\_FL](https://www.academia.edu/23181259/Investigacion_de_operaciones_9na_Edicion_Hamdy_A_Taha_FL) Consultado el 27/06/2020.
- Tobón, J. (2020). Desarrollo de un modelo de pronóstico en la metodología de Box-Jenkins para la demanda de estudiantes de pregrado de la Fundación Universitaria Tecnológico Comfenalco de la ciudad de Cartagena de indias desde 2002 a 2018. (Trabajo de grado). Disponible en: [https://repository.libertadores.edu.co/bitstream/handle/11371/2792/Guzm%C3%A1n\\_%20Juan\\_2019.pdf?sequence=1](https://repository.libertadores.edu.co/bitstream/handle/11371/2792/Guzm%C3%A1n_%20Juan_2019.pdf?sequence=1) Consultado el 21/05/2020.
- van der Aalst, W., Rubin, V., van Dongen, B., Kindler, E. y Günther, C. (2006). Process mining: A two-step approach using transition systems and regions. BPM Center Report BPM-06-30, BPMcenter.org, 6. Disponible en: <http://www.padsweb.rwth-aachen.de/wvdaalst/publications/p359.pdf> Consultado el 10/08/2020.
- Velásquez, J. (2004). Pronóstico de la serie de Mackey-Glass usando modelos de regresión no lineal. Dyna, 71(142), 85-95. Disponible en: <https://www.redalyc.org/pdf/496/49614209.pdf> Consultado el 16/11/2020.
- Yan, X. (2009). Linear Regression Analysis: Theory and Computing. New York: World Scientific Publishing Company