

PRONÓSTICOS DE LA DEMANDA PARA UNA EMPRESA DE PARTES AUTOMOTRICES: CASO DE ESTUDIO

DEMAND FORECASTING FOR AN AUTOMOTIVE PARTS COMPANY: CASE STUDY

Victor Sánchez-Guzmán, Javier García-Gutiérrez, Araceli Osorio-Jaramillo

Facultad de Ingeniería de la Universidad Autónoma del Estado de México.

Cerro de Coatepec S/N Ciudad Universitaria C.P. 50100. Toluca, Estado de México.

Email: jgarciagtz@yahoo.com.mx; Torres: <https://orcid.org/0000-0001-9830-7630>

RESUMEN

La industria de repuesto de partes automotrices, se ve beneficiada por la precisión de poder pronosticar el futuro, por lo que hacer uso de mejores herramientas, y lograr mejores pronósticos, se traduce en la posibilidad de llevar a cabo una planeación que permita un mejor desempeño de la empresa, aumentando su nivel de servicio y reduciendo sus costos.

El presente artículo nos muestra una metodología general para calcular el pronóstico de la demanda en una empresa del ramo de partes de repuesto automotriz, para atacar la falta de consistencia en la manera de realizar el cálculo del pronóstico y al mismo tiempo, otorgar una solución mediante la búsqueda y prueba de una mejor técnica, esta técnica será comparada con las metodologías tradicionales para el cálculo de pronósticos.

El trabajo lo abordamos mediante una metodología basada en la técnica estadística Box-Jenkins de series de tiempo que ayuda a conocer la demanda, utilizando una herramienta más confiable que disminuya el error al momento de calcular el pronóstico y mejorar su eficiencia, para que resulten mejores tomas de decisiones a la hora de realizar pedidos y de esta forma, se optimicen recursos al disminuir gastos de inventarios innecesarios.

La investigación se enfoca en revisar el tipo de demanda que presenta el mercado de repuesto de partes automotrices. Por lo cual, la metodología que propondremos abarca todos aquellos artículos clasificados como A, dentro de una clasificación ABC, logrando con esto evaluar sólo aquellos productos de mayor peso en la organización, que contribuyan de manera importante a mejorar la precisión en el cálculo de su pronóstico.

Palabras clave: Demanda; Pronósticos; Series de Tiempo; Metodología Box-Jenkins.

ABSTRACT

The spare parts industry, is benefited by the precision of being able to forecast the future, so making use of better tools, and achieving better forecasts, is translates into the possibility of carrying out a planning that allows a better performance of the company, increasing its level of service and reducing its costs.

This article shows a general methodology to calculate the forecast of the demand in a company of the spare parts, to attack the lack of consistency in the way of calculating the forecast and at the same time, provided a solution through

the search and proof of a better technique, the technique is compared with the traditional methodologies for calculating forecasts .

The work is approached through a methodology based on the Box-Jenkins statistical technique of time serial, which will help to know the demand, using a reliable tool to reduce the mistake in the forecast calculus and improves its efficiency, allowing that the decisions can be taken in the best way and the resources optimized, reducing inventory costs.

This investigation will focus exclusively to the demand existing in the aftermarket parts. Therefore, the methodology that we will propose encompasses all those articles classified as A, within an ABC classification, thus achieving to evaluate only those products of greater weight in the organization, which contribute significantly to improve the accuracy in the calculation of their forecast.

Keywords: Demand; Forecast; Time Serial; Box-Jenkins Methodology.

INTRODUCCIÓN

El proceso de pronosticar constituye la base o el fundamento para cualquier planeación de productos o servicios que se requieran fabricar, comprar o vender, es decir, en medida que las organizaciones cuenten con un pronóstico preciso contarán con un nivel de artículos disponibles, que invariablemente proporcionará a las compañías mayor precisión para el cumplimiento de pedidos, lo que incrementará el nivel de servicio y por consiguiente la satisfacción por parte del cliente.

En la actualidad los directivos descuidan el aspecto en la utilización de mejores técnicas estadísticas para realizar cálculos de pronósticos, provocando que las organizaciones no puedan reaccionar ante la demanda variable de los clientes al no predecir un pronóstico preciso, impactando en el costo de mantener inventarios y por faltantes, provocando por consiguiente niveles de servicio bajos y almacenes con demasiado producto (Ballou, 2004).

Con la tecnología que se cuenta en nuestros días, resulta difícil aceptar que las organizaciones sigan manteniendo sistemas de gestión de demanda basados sólo en la experiencia o en el uso de técnicas elementales.

Por lo tanto, el presente trabajo de investigación plantea una metodología que ayude y facilite a las organizaciones

la utilización de técnicas más desarrolladas que permitan pronosticar con un mayor grado de precisión su demanda.

El problema abordado, es el pronóstico de la demanda de repuesto de partes automotrices para una empresa mexicana con mercado nacional. Pronosticar la demanda de partes de repuesto es notablemente difícil ya que la demanda es generalmente variable e inestable (Teunter et al., 2012).

Existen estudios relacionados con mejoras en la administración de la cadena de suministros de diferentes tipos de parte de repuesto, en algunos casos mediante la elaboración de pronósticos más acertados, en otros proponiendo mejoras en la gestión directa de los inventarios. Para algunos de estos estudios, se han utilizado métodos de pronóstico diferentes a las series temporales para estimar las demandas de los próximos periodos, obteniendo pronósticos más precisos cuando los métodos son combinados (Do Rego y Mesquita, 2011). Las empresas que distribuyen partes de repuesto deben estudiar la información disponible acerca de las unidades vendidas por intervalos de tiempo, ciclos de vida de los productos, el *lead time* de las refacciones, inventarios en almacenes o centros de servicio, y analizando estos datos, estimar los requerimientos de refacciones para acoplar su logística con respecto a las conclusiones obtenidas (Dekker et al., 2013). En este caso de estudio, se utilizan las series temporales como herramientas de modelado y pronóstico. Existen varios estudios que han utilizado esta herramienta de manera independiente, comparativa o combinada en busca de una mayor precisión. En publicaciones recientes, se puede observar la comparación de diferentes modelos para el pronóstico de series de tiempo, involucrando los modelos *Autoregressive Integrated Moving Average* (ARIMA) y *Artificial Neural Network* (ANN). En la mayoría de los casos, los modelos ANN excedieron la calidad del pronóstico sobre los modelos ARIMA (Ansuji et al., 1996). Sin embargo, también hay casos en los que los modelos ARIMA funcionaron mejor (Koutroumanidis et al., 2009).

Otro caso de estudio para una empresa transnacional de partes de repuesto, donde se evalúan herramientas de modelado de series temporales aplicadas a la previsión mensual de la demanda en México (Vargas y Cortes, 2017). En este caso se comparan los métodos clásicos, ARIMA, ANN y los modelos híbrido ARIMA-ANN. En donde se observa un buen desempeño de los modelos ANN con mejor precisión que los ARIMA, sin embargo, no fueron tan estables como los modelos ARIMA cuando los periodos de planeación son más largos. El *Mean Absolute Percentage Error* (MAPE) se redujo de 57% que la empresa tenía al inicio del estudio, a un 32,65% utilizando estos modelos combinatorios.

Como una alternativa a estos tipos de demanda, se han propuesto modelos combinatorios para mejorar la precisión del pronóstico, obteniendo un pronóstico más preciso que cuando son utilizados por separado (Koutroumanidis et al., 2009).

METODOLOGÍA

La metodología propuesta para el cálculo del pronóstico de la demanda para una empresa de repuesto de partes automotrices es la siguiente:

1. *Análisis de Pareto*: Se realizó un análisis 80-20% con la finalidad de trabajar con los productos que mayor demanda presentan en el mercado.

2. *Información*: Definir con que información se cuenta para seleccionar el tipo de método para el cálculo del pronóstico de la demanda.

3. *Demanda*: Estudiar el comportamiento de la demanda para seleccionar los métodos de pronóstico que se utilizaran.

4. *Selección del pronóstico*: Con base al estudio realizado con anterioridad.

5. *Evaluar la técnica seleccionada*.

6. *Selección del pronóstico más preciso*: Con base en la estimación del MAPE.

7. *Evaluación de las metodologías*: Comparación de los métodos utilizados para el cálculo de los pronósticos.

(Makridakis et al., 1997). Sugiere que para la obtención de una técnica de pronóstico debe considerarse un análisis de los datos antes de decidir el método de pronóstico a utilizar, si los datos presentan patrones que se repiten con el tiempo como tendencia o estacionalidad, o aquellos que no se repiten en un intervalo fijo de tiempo y que se pueden considerar cíclicos, como lo muestra la Figura 1.

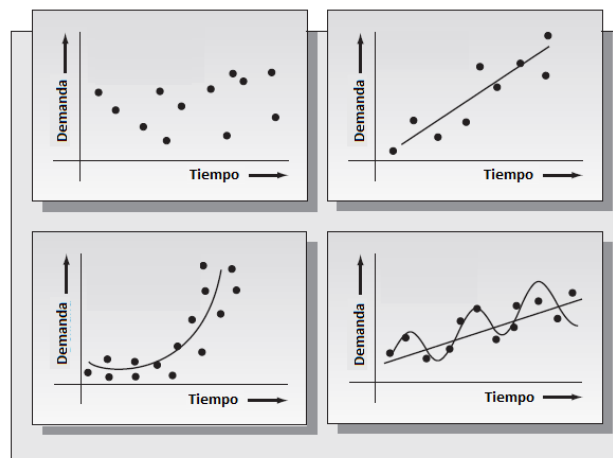


Figura 1. Patrones de series de tiempo. (Nahmias, S. y Lennon, O., 2015).

ANÁLISIS DE AUTOCORRELACIÓN

Un instrumento útil en el análisis de series de tiempo es la función de autocorrelación (ACF por sus siglas en inglés *Autocorrelation Function*), ver Figura 2.

La ACF de la serie de tiempo Y_1, Y_2, \dots, Y_n con retraso (lag) k está dada por:

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

Se utilizan para medir el grado de asociación entre Y_t y Y_{t-1} cuando los efectos de otros tiempos (*lags*) 1,2,3, ..., $k - 1$ son removidos.

Supongamos que hay una autocorrelación significativa Y_t y Y_{t-1} , entonces habrá una correlación significativa entre Y_{t-1} y Y_{t-2} ya que son unidades de tiempo aparte. Por lo tanto, habrá una correlación entre Y_t y Y_{t-2} porque ambos están relacionados con Y_{t-1} .

Entonces, para medir la correlación real entre Y_t y Y_{t-2} se necesita sacar el valor intermedio Y_{t-1} . Esto es lo que hace la autocorrelación parcial (PACF *Partial Autocorrelation Function*), como lo muestra la Figura 3.




Figura 2. ACF para serie de tiempo AR (1). (Makridakis et al., 1997).




Figura 3. PACF para serie de tiempo AR (1). (Makridakis et al., 1997).

La técnica utilizada es la metodología ARIMA, esta metodología contempla a todos los patrones de datos sin considerar sus componentes individuales, utiliza modelos de series de tiempo y el horizonte de planeación es de corto a mediano plazo, una desventaja radica en que para la utilización de esta técnica se requieren al menos de 36 datos [8], lo que es fácilmente superado por aquellas organizaciones que tienen más de 4 años de permanencia en el mercado.

Esta técnica se compara con las técnicas tradicionales de pronósticos de suavizamiento exponencial simple, suavizamiento exponencial doble y promedios móviles,

con base en el menor MAPE se identificó al mejor modelo de pronóstico.

METODOLOGÍA BOX-JENKINS

La metodología Box-Jenkins define cuatro modelos para representar las series estacionarias:

AR(p) Autorregresivo de orden p.

MA(q) Promedio Móvil de orden q.

ARMA(p,q) Autorregresivo de orden p y promedio móvil de orden q.

ARIMA(p,d,q) Autorregresivo y promedio móvil diferencia d de Y_t .

Modelos de Media Móvil, MA (q):

$$Y_t = b_0 + b_1 e_{t-1} + \dots + b_q e_{t-q}$$

En los modelos de media móvil, el proceso se representa como una suma ponderada de errores actuales y anteriores. El número de rezagos del error considerados (q) determina el orden del modelo de media móvil.

Modelos Autorregresivos, AR (p):

$$Y_t = b_0 + b_1 Y_{t-1} + \dots + b_p Y_{t-p}$$

En los modelos autorregresivos, el proceso se representa como una suma ponderada de observaciones pasadas de la variable. El número de rezagos (p) determina el orden del modelo autorregresivo.

Modelos Mixtos Autorregresivos-Media Móvil, ARMA (p,q):

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \theta_0 + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q}$$

En estos modelos, el proceso se representa en función de observaciones pasadas de la variable y de los valores actuales y rezagados del error. El número de rezagos de la variable de interés (p) y el número de rezagos del error (q) determinan el orden del modelo mixto.

Modelos Autorregresivos Integrados de Promedio Móvil, ARIMA (p,d,q):

Un tipo especial de series no estacionarias, son las no estacionarias homogéneas que se caracterizan porque, al ser diferenciadas una o más veces, se vuelven estacionarias.

Si después de haber diferenciado la serie Y_t se consigue una serie estacionaria W_t , y dicha serie obedece a un proceso ARMA(p,q), se dice que Y_t responde a un proceso ARIMA(p,d,q):

$$W_t = \phi_0 + \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + \theta_0 + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q}$$

Definida la técnica a utilizar, se procederá a evaluar de entre diferentes arreglos de los métodos autorregresivos (AR) la diferenciación (I) y los modelos de promedio móvil (MA), aquél que presente el menor error del pronóstico apoyándonos con el MAPE.

RESULTADOS

La Tabla 1 muestra la serie de tiempo con 48 datos de demanda para el producto K8432, el objetivo es determinar el modelo con el mejor ajuste para pronosticar la demanda de los siguientes periodos, el mismo procedimiento se realizó para todos los productos A del Análisis de Pareto, realizado en la primera etapa de la metodología.

Tabla 1. Demandas producto K8432.

Mes	Demanda K8432			
	2015	2016	2017	2018
Ene.	184	114	184	173
Feb.	186	283	118	236
Mar.	471	250	158	393
Abr.	137	163	108	221
May.	127	312	279	180
Jun.	224	122	177	136
Jul.	317	130	189	104
Ago.	267	220	188	119
Sep.	238	235	115	132
Oct.	199	176	214	186
Nov.	133	190	219	151
Dic.	371	172	135	251

Elaboración propia

En la Figura 4, se presenta grafica de serie de tiempo para el producto K8432, se observa una demanda variable, además de no presentar estacionalidad y ningún tipo de tendencia (un poco de tendencia negativa), que podría suponerse que la serie de tiempo es estacionaria.

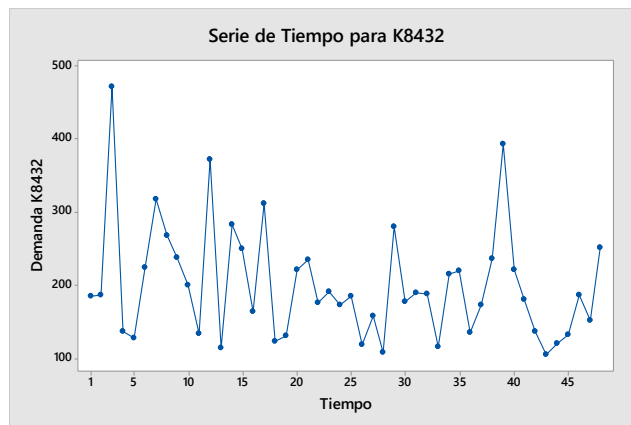
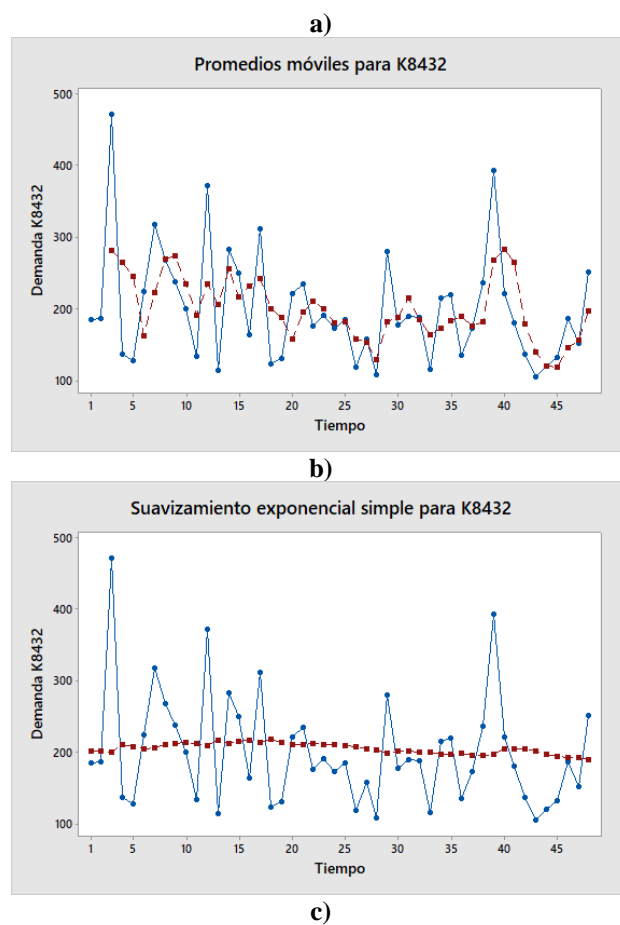


Figura 4. Serie de tiempo para K8432. Elaboración propia.

La Figura 5, muestra las graficas y el ajuste para las diferentes tecnicas tradicionales de pronosticos utilizadas en el caso de estudio.



c)




Figura 5. Modelos de pronósticos: a) Promedios móviles, b) Suavizamiento exponencial y c) Suavizamiento exponencial doble. Elaboración propia.

En la Figura 6, se presentan las funciones de autocorrelación y autocorrelación parcial del producto K8432, las cuales sirven como base para proponer los mejores modelos ARIMA que podrían ajustarse a la serie de tiempo. Los modelos ARIMA propuestos fueron ARIMA (1,1,0), ARIMA (0,1,1) y ARIMA (1,1,1). ARIMA (1,1,1) es el modelo que mejor se ajusta de los tres modelos propuestos, este modelo es seleccionado, por presentar el menor MAPE de los tres modelos propuestos.


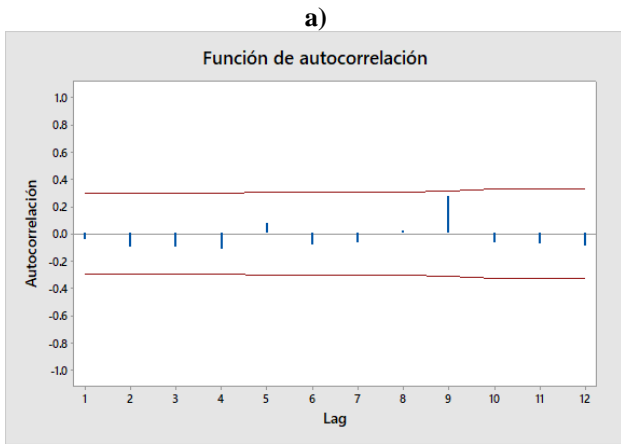


Figura 6. Funciones de autocorrelación (a) y autocorrelación parcial (b). Elaboración propia.

DISCUSIONES

La tabla 2, muestra las medidas de desempeño para los modelos propuestos. Se observa el modelo ARIMA (1, 1, 1) es modelo que se ajusta mejor por presentar el MAPE más bajo en comparación con los modelos tradicionales. Se observa también que de los modelos tradicionales el de mejor ajuste es promedios móviles.

El modelo ARIMA (1, 1, 1) en comparación con promedios móviles de los métodos tradicionales es muy cerrado y más cuando a la serie de tiempo se le realiza una transformación logarítmica para reducir las variaciones de la media como lo indica (Vargas y Cortes, 2017).

Se observaron ciertas ventajas con el modelo ARIMA que a partir de la función de autocorrelación se proponen modelos que pueden ajustarse y seleccionar al mejor modelo en comparación con los modelos tradicionales que debemos establecer valores de α y β (suavizamiento exponencial simple y doble) que en algunas ocasiones puede ser no conveniente y por lo tanto los modelos no se ajustan como se esperaba.

Durante la revisión bibliografía se encontró que algunos pronósticos para piezas de repuestos tienden a ser muy variables al utilizar estas técnicas tradicionales (Teunter et al., 2012), debido a la demanda variable que presentan las piezas de repuesto, pero es mejor tener una aproximación a las demandas futuras, por lo que vale la pena mantener los esfuerzos para mejorar nuestra comprensión de estas técnicas.

Tabla 2. Medidas de desempeño de los modelos propuestos antes y después de realizar transformación logarítmica a la serie de tiempo.

Modelo	Sin transformación		Con transformación	
	MS	MAPE	MS	MAPE
Promedios móviles	5471	29.15	0.121	5.25
Suavizamiento exponencial simple	6134	33.16	0.128	5.46
Suavizamiento exponencial doble	9283	39.92	0.193	6.81
ARIMA (1,1,1)	4316	26.89	0.086	4.67

Elaboración propia.

CONCLUSIONES

- Se concluye que el modelo autorregresivo integrado de medias móviles (ARIMA) (1, 1, 1) propuesto, es el apropiado en el cálculo del pronóstico de la demanda para el artículo K8432 de la empresa en estudio, y este resulta de gran

utilidad en la toma de decisiones al proporcionarnos los pronósticos precisos.

- En relación con los resultados obtenidos y a los registrados, se concluye que el uso de los métodos estadísticos en la estimación de pronósticos, son útiles en la toma de decisiones para la selección del mejor modelo de pronóstico, debido a sus resultados en pronósticos precisos.
- Los modelos clásicos son los más fáciles y rápidos para trabajar, y proporcionan buenos resultados cuando se enfrentan a un comportamiento de la demanda poca variable. Los modelos ARIMA son muy prometedores y con un buen ajuste, para demandas variable, pero cuando la demanda es muy errática no se recomiendan (Teunter et al., 2012).
- Es importante mencionar que hasta el momento el modelo no ha sido validado, pero la siguiente fase del modelo es su validación en la empresa del caso de estudio.

two-step method for forecasting spare parts demand using information on component repairs, *European Journal of Operational Research*, vol. 220, p. 386-393.

Vargas, C. G. y Cortés, M. E. (2017) «Automobile spare-parts forecasting: A comparative study of time series methods,» *International Journal of Automotive and Mechanical Engineering*, vol. 14, p. 3898-3912.

REFERENCIAS

Ansuji, A., Camargo, M., Radharamanan, R. y Petry, D., (1996). «Sales Forecasting using time series and neural networks,» *Computer & Industrial Engineering*, vol. 31, p. 421-424.

Ballou, R. H. (2004) *Logística Administración de la Cadena de Suministro*, México: PEARSON Educación.

Dekker, R., Pince, C., Zuidwijk, R. y Naiman, M., (2013). «On the use of installed base information for spare parts logistics: A review of ideas and industry practice,» *Int. J. Production Economics*, vol. 143, p. 536-545.

Do Rego, J. y Mesquita, M. (2011). Spare Parts Inventory Control: A Literature Review,» *Production*, vol. 21, n° 4, p. 645-666.

Koutroumanidis, T., Ioannou, K. y Arabatzis, G. (2009). «Predicting fuelwood prices in Greece with the use ARIMA models, artificial neural networks and a hybrid ARIMA-ANN model,» *Energy Policy*, vol. 37, p. 3627-3634.

Makridakis, S., Wheelwright, S. y Hyndman, R. (1997) *Forecasting Methods and Applications*, Wiley.

Nahmias, S. y Lennon, O. T. (2015). *Production and Operations Analysis*, Long Grove, IL: Waveland Press, Inc.

Teunter, R., Jaarsveld, W. y Romeijnnders, W. (2012). A