

Comparativo de métodos de pronóstico en series de tiempo para la demanda de repuestos automotrices

Comparison of time series forecasting methods for automotive spare parts demand

¹Erika Montes de Oca-Sánchez ^{1*}Lourdes Loza-Hernández

¹Departamento de Posgrado, Facultad de Ingeniería, Universidad Autónoma del Estado de México. Ciudad Universitaria s/n, C. P. 50100, Toluca, Estado de México, México. Correo electrónico: mitakire@gmail.com; llozahe@gmail.com ORCID: <https://orcid.org/0000-0002-6577-9794>; <https://orcid.org/0000-0001-5107-7110>

*Autor para correspondencia

Recibido: 23 de marzo del 2024
Aceptado: 17 de enero del 2025
Publicado: 31 de enero del 2025
<https://doi.org/10.33064/iycuaa2025945451>
e5451

RESUMEN

La inevitable necesidad que las empresas del sector de repuestos automotrices tienen de pronosticar sus niveles de producción es la base del desarrollo de este trabajo. Este artículo muestra el análisis probabilístico de la demanda de tres empresas de autopartes mexicanas enfocadas a la producción y venta nacional e internacional. Se analizaron 312 series de tiempo basadas en el histórico mensual de demanda, aplicando métodos de pronóstico como promedios móviles, Winters, descomposición multiplicativa, ARIMA (Box - Jenkis), Croston y aproximación de Syntetos-Boylan (SBA) para encontrar la mejor medida de bondad de ajuste. El desempeño de cada método se evaluó a través del error porcentual absoluto (MAPE) y el error cuadrático medio (MSE). Los resultados mostraron una reducción del 60.77% del MAPE en el patrón suave y del 70.60% en el errático. Esta investigación contribuye a la literatura del sector de autopartes para apoyar en la toma de decisiones.

Palabras clave: pronóstico de la demanda; mercado de autopartes; patrones de demanda; cadena de suministro; series de tiempo.

ABSTRACT

The inevitable need for companies in the automotive spare parts sector to forecast their production levels is the basis for the development of this work. This article shows a probabilistic analysis of the demand of three Mexican auto parts companies focused on production and sale at a national and international level. 312 time series were analyzed based on the monthly historical demand by applying forecasting methods such as moving averages, Winters, multiplicative decomposition, ARIMA (Box - Jenkis), Croston, and Syntetos-Boylan Approximation (SBA) to find the best goodness-of-fit measure. The performance of each method was evaluated through the absolute percentage error (MAPE) and the mean

squared error (MSE). The results showed a reduction of 60.77% of MAPE in the smooth pattern and 70.60% in the erratic. This research contributes to the literature of auto parts sector to support decision making.

Keywords: demand forecast; spare parts; demand patterns, supply chain; automotive time series.

INTRODUCCIÓN

El diseño de estrategias efectivas que impulsen mejoras dentro de la cadena de suministro del sector de repuestos automotrices en México continúa siendo un área de oportunidad debido a su constante evolución. En el país se han instalado las principales empresas de autopartes de Norteamérica, Europa y Asia, para garantizar entregas "justo a tiempo" y facilitar la flexibilidad productiva que requieren las ensambladoras; México es el quinto productor a nivel mundial, justo detrás de China, Estados Unidos, Japón y Alemania, el principal proveedor de la industria automotriz establecida en la región de Norteamérica, y el primer país de América Latina para 2017. Para finales de 2021 se pronosticó un crecimiento de 19.6%, lo que representa un valor de producción de repuestos automotrices de US 93,788 millones y alcanzar los US 98,656 millones para 2022, convirtiendo a la industria automotriz en la principal generadora de divisas netas para México, debido a su gran cadena de suministro (Industria Nacional de Autopartes, A. C., 2018; Balderas, 2021). El constante cambio y proceso acelerado del sector de autopartes requiere comprender el comportamiento de su demanda, así mismo, contar con herramientas que permitan fortalecer la toma de decisiones en la administración de recursos; siendo la predicción el punto de partida para la mayoría de las decisiones en la gestión de la cadena de suministro, donde la capacidad de predecir la demanda del cliente con precisión es el éxito de una cadena de suministro de fabricación; entendiendo como precisión en el pronóstico la diferencia entre lo real y lo pronosticado es un margen de error admisible para la empresa (Ravindran y Warsing, 2013).

En la industria de repuestos para autopartes existe una gran variedad de factores que provocan variabilidad en la demanda de los productos, por lo tanto, obtener pronósticos con un nivel de confianza aceptable se vuelve complejo, por lo que éstos son vitales para seguir siendo competitivos dentro del sector. El propósito de este artículo es proporcionar métodos de pronóstico cuantitativo para el análisis probabilístico de la demanda de las empresas mexicanas de autopartes enfocadas a la producción y venta a nivel nacional e internacional, que permita apoyar la toma de decisiones confiables en las etapas

posteriores de la cadena de suministro. Por ello, la aplicación de metodologías y técnicas para analizar y determinar pronósticos con altos niveles de confianza es de vital importancia. Para lograr el objetivo, se consideraron diferentes métodos de pronóstico para cada una de las 312 autopartes de estudio, finalmente la elección del mejor de método de pronóstico se basa sobre el error porcentual absoluto (MAPE) más bajo y el error cuadrático medio (MSE) del pronóstico obtenido.

Los resultados esperados en una organización en temas como adquisiciones, fabricación, logística, marketing, planificación financiera, etc. dependen del impacto de la incertidumbre de la demanda en la rentabilidad general, por lo que es fundamental contar con un método eficaz de previsión. En consecuencia, para los participantes de la cadena de suministro es un desafío tener un pronóstico correcto (Kumar, Herbert y Rao, 2015). En el sector automotriz las autopartes son muy variadas lo mismo que sus costos y por ende sus patrones de demanda, por lo que una clasificación adecuada de las piezas de repuesto es útil para tomar decisiones de pronóstico y control de inventarios (Boylan y Syntetos, 2007; Bucher y Meissner, 2011).

En términos generales, este documento se constituye de cinco secciones, la primera sección muestra una breve descripción de los métodos propuestos por la literatura en la clasificación y métodos de pronóstico de la demanda de repuestos automotrices; la segunda sección describe los procedimientos metodológicos involucrados y los datos utilizados en la investigación; los resultados son mostrados en la tercera sección, dando paso a la sección cuatro donde se encuentra una discusión sobre los hallazgos encontrados. Finalmente, se presentan las conclusiones derivadas del análisis realizado en los apartados anteriores.

Revisión de literatura

El mercado de la industria automotriz es cada vez más competitivo, mantenerse en él y cumplir con las expectativas de los clientes es complicado, por ello, es fundamental crear estrategias que permitan identificar oportunidades de mejora en las diferentes etapas de la cadena de suministro. Diaz, Hennequin y Roy (2020) consideran los repuestos como un área clave de la industria automotriz, debido a que cuando los vehículos dejan de comercializarse no es el final de la producción de sus componentes. De hecho, es necesario ofrecer repuestos a los clientes por un periodo mínimo de 10 años. De ahí que mantener la satisfacción y confianza del consumidor es muy importante en el mercado de las

autopartes; la correcta gestión de los repuestos es por lo tanto vital, ya que la previsión de la demanda juega un papel clave para lograrlo (Alalawin, Arabiyat, Alalaween, Qamar y Mukattash, 2021; Vasumathi y Saradha, 2013). A nivel de componentes o de producto final, la previsión de la demanda es una tarea complicada debido a la gran variedad de componentes, demandas muy inestables (desde unas pocas unidades por año hasta miles por mes), y riesgo de obsolescencia, por lo que la identificación de una estrategia de control de inventario adecuada para cada pieza es difícil y representa un desafío importante en la gestión de inventarios (Chatras, Giard y Sali, 2015; Hu, Boylan, Chen, y Labib, 2017; Do Rego y De Mesquita, 2015).

Clasificación de la demanda. La aplicación de un modelo de categorización práctico proporciona la base para un sistema de inventario administrado eficientemente, que le brinda al gerente de la empresa una mejor visión del número de unidades de almacenamiento (SKU) que deben administrarse; además, permite tomar decisiones de pronóstico y control para cada subgrupo formado a partir de la implementación del modelo (Bucher y Meissner, 2011). El principio de Pareto o regla 80-20 es uno de los métodos de clasificación más utilizados por la industria. El análisis, conocido como análisis ABC, tiene como objetivo proporcionar reglas de decisión simples que determinen a través de un único criterio como la variabilidad del precio, los ingresos o la diferencia de variabilidad de la demanda entre todas los SKU de la empresa. Los criterios seleccionados del análisis (valor total de las ventas o el volumen de productos) ordenar todos los SKU en orden descendente, utilizando tres lugares de ranking de prioridad: los SKU más rentables en el grupo A y los menos en el grupo C, los de importancia intermedia están en el grupo B; esto quiere decir que, el grupo A tiene una participación del 80%, el grupo B un 15% y el último 5% es el grupo C (Boylan y Syntetos, 2007; Engelmeyer, 2016; Mehdizadeh, 2020; Silver, Pyke y Thomas, 2017).

Autores como Eaves y Kingsman (2004), Hua, Zhang, Yang y Tan (2007), Pennings, Van Dalen y Van Der Laan (2017), Romeijnders, Teunter y Van Jaarsveld (2012), Syntetos, Babai y Altay (2012) consideran que la demanda de repuestos es intermitente, es decir, que la demanda aparece aleatoriamente en el tiempo, con periodos que no tienen demanda. La variabilidad del tamaño de la demanda es un método complementario de categorización, donde los patrones de demanda intermitente se caracterizan por demandas poco frecuentes, a menudo de tamaño variable, que ocurren a intervalos irregulares (Boylan y Syntetos, 2007; Syntetos et al., 2012). Williams (1984) consideró la varianza del número de

pedidos y su tamaño dado un tiempo de entrega particular, clasificando los artículos mediante el coeficiente de variación (CV^2) en categorías según la intermitencia y el tamaño de la demanda alta/baja. Se crea una categoría particular para productos con una ocurrencia de demanda altamente esporádica y alta variación en el tamaño de la demanda, con base a la intermitencia de la demanda, sin embargo, menciona que la elección de los límites entre categorías es una decisión administrativa que depende del sector y tipo de artículo. Además, Eaves y Kingsman (2004) amplían las categorías de patrones de demanda de Williams (1984) como suaves, irregulares, de movimiento lento e intermitentes, dividiéndose este último en ligera y altamente intermitentes. Esta modificación se realiza para establecer el límite de variabilidad de la transacción en el cuartil inferior, mientras que los límites de variabilidad del tamaño de la demanda y el tiempo de entrega se establecen en sus respectivas medianas.

Johnston y Boylan (1996) introdujeron el concepto de intervalo de demanda promedio (ADI), que indica la intermitencia de la demanda y Syntetos, Boylan y Croston (2005) categorizan la demanda en términos de ADI y CV^2 de los tamaños de demanda. (con el CV^2 indicando la variabilidad de la demanda). Las ecuaciones 1 y 2 muestran los parámetros utilizados para calcular cada término (Şahin, Kızılaslan y Demirel, 2013).

$$ADI = \frac{\sum_{i=1}^{N-1} t_i}{N-1} \quad (1)$$

Dónde:

N : indica el número de períodos con demanda distinta de cero,

t_i : es el intervalo entre dos demandas consecutivas.

$$CV^2 = \frac{\sum_{i=1}^n (D_i - \bar{D})^2}{(n-1) \bar{D}^2} \quad (2)$$

Dónde:

n : es el número de periodos,

D_i y \bar{D} : son la demanda actual en el periodo i y la demanda promedio .

Los valores de corte para la clasificación de los patrones sugeridos por Syntetos et al. (2005) son $ADI = 1.32$ y $CV^2 = 0.49$ y dependiendo de la intermitencia y variabilidad de la demanda se puede clasificar en una de las 4 categorías presentadas en la Tabla 1.

Tabla 1
Patrones de demanda

Patrón	ADI	CV ²	Descripción
Suave	≤ 1.32	≤ 0.49	Demanda regular en el tiempo y poca variabilidad en el tamaño de la demanda.
Errática	≤ 1.32	> 0.49	Distribución regular de la demanda en el tiempo con fuerte variabilidad en la cantidad de demanda.
Granulada o irregular	> 1.32	> 0.49	Intervalos de demanda irregular en el tiempo, considerable número de periodos con demanda cero y mayor variabilidad en el tamaño de la demanda.
Intermitente	> 1.32	≤ 0.49	Intervalos con demanda irregular en el tiempo, sin acentuada variabilidad en la cantidad demandada

Fuente: Elaboración propia, con base en (Costantino, Di Gravio, Patriarca, y Petrella, 2017; Rožanec y Mladenec, 2021).

Métodos de pronósticos. La base de toda planificación de la cadena de suministro es la previsión de la demanda (Chopra y Meindl, 2008). Para Ravindran (2008) el pronóstico es una predicción o estimación del futuro, las técnicas de pronóstico apropiadas pueden reducir el stock de seguridad y los costos sin perjudicar los niveles de servicio (Romeijnders et al., 2012). El principal problema, que hace que la previsión de la demanda de repuestos de automóviles sea un proceso complejo, es que la demanda se considera intermitente, además de verse afectada por factores como la política de mantenimiento, la tasa de fallos del producto, etc. (Alalawin et al., 2021).

Dada la variedad de tipos de demanda, los investigadores propusieron múltiples enfoques para proporcionar pronósticos de demanda precisos. Mientras que las demandas suaves y erráticas logran buenos resultados utilizando modelos de regresión, la demanda intermitente e irregular requiere modelos especializados que consideren la ocurrencia de la demanda (Rožanec y Mladenec, 2021). Los métodos de pronóstico tradicionales incluyen métodos de series de tiempo si la demanda histórica sigue un patrón determinado y si este patrón puede analizarse, puede usarse para desarrollar un pronóstico para la demanda futura, si el patrón continúa aproximadamente de la misma manera. Algunos de los principales métodos de series de tiempo incluyen promedios móviles, suavizado exponencial, análisis de regresión ver (Anderson, Sweeney y Williams, 2008; Axsäter, 2006), ARIMA (Box-Jenkins) y descomposición de series de tiempo (Chapman, 2006).

El patrón de demanda intermitente hace que la previsión de la demanda sea un ejercicio desafiante, ya que las técnicas de previsión estándar a menudo producen resultados inexactos. Por lo tanto, se han desarrollado técnicas de previsión específicas para la demanda intermitente de repuestos (Van, Boute y Syntetos, 2019).

Ghobbar y Friend (2003) proponen un nuevo enfoque para la evaluación de pronósticos, donde un modelo predictivo de pronóstico de errores evalúa y compara 13 métodos diferentes basados en diferentes factores que presentan artículos con demanda intermitente y encuentran una superioridad sobre el método de Croston, Holt y de media móvil ponderada. Eaves y Kingsman (2004) comparan los métodos Croston, aproximación (modificación del método de Croston con suavizamiento exponencial), suavizamiento exponencial y media móvil, encontrando que el mejor método de previsión para un inventario de repuestos es el método de aproximación. Este método permite mantener las existencias más bajas en todos los patrones de demanda, incluidos los suaves, irregulares, de lento movimiento e intermitentes. Por otro lado, Willemain, Smart y Schwarz (2004) presentaron un enfoque de arranque que durante un tiempo de entrega fijo, se puede pronosticar la suma de las demandas intermitentes; con este método de arranque no paramétrico, los autores respaldan pronósticos más precisos sobre productos con demandas intermitentes que el suavizado exponencial y el método de Croston. Sin embargo, mencionan requerir mayor evidencia empírica para verificar los beneficios que ofrece dicho enfoque no paramétrico. Teunter y Duncan (2009) son autores que también han discutido los beneficios de un método bootstrap para el pronóstico de la demanda intermitente. Hua et al. (2007) desarrollan un método de pronóstico integrado (IFM), el enfoque proporciona un mecanismo para integrar el proceso de demanda autocorrelacionada y la relación entre las variables explicativas y la demanda distinta de cero de piezas de repuesto en el pronóstico de ocurrencias de demandas distintas de cero durante los plazos de entrega; compararon el rendimiento del suavizado exponencial, el método de Croston y el método de arranque de Markov con su IFM. Los resultados estadísticos muestran que su método funciona mejor en casi todos los plazos de entrega. Altay, Rudisill y Litteral (2008) comparan una modificación del método de Croston y un método basado en el doble suavizado exponencial de Holt como una alternativa viable cuando la previsión de la demanda mantiene la tendencia presente. Lindsey y Pavur (2008) extienden el método de Croston a la demanda intermitente cuando la probabilidad de que ocurra la demanda no es constante con la modificación de utilizar un suavizamiento doble exponencial en el tiempo entre demandas. Teunter, Syntetos y Babai (2011) proponen un nuevo método insesgado (para todos los momentos), diferente al método de Croston, y que actualiza la probabilidad de demanda en lugar del intervalo de demanda, haciéndolo en cada período. Los resultados indican un rendimiento superior y permiten obtener información sobre el vínculo entre la previsión de la demanda y la obsolescencia.

Hasta ahora, el método de Croston y la aproximación de Syntetos y Boylan (SBA) son los enfoques más utilizados para la previsión de demanda irregular (Hellingrath y Cordes, 2014; Vasumathi y Saradha, 2013). Croston (1972) desarrolló un método clásico para pronosticar la demanda intermitente, que utiliza dos estimaciones de suavizamiento exponencial separadas para pronosticar el tamaño de la demanda y el intervalo entre demandas distintas de cero. Estas estimaciones se actualizan sólo cuando se produce la demanda. Considere la siguiente notación para explicar el procedimiento de Croston (Xu, Wang y Shi, 2012):

z_t : demanda en el periodo t

\hat{Z}_t : pronóstico del tamaño de la próxima demanda más allá del periodo t

z^* : Promedio de la demanda por periodo

p_t : tiempo entre dos demandas positivas

\hat{P}_t : pronóstico del intervalo de demanda

q : intervalo de tiempo de la última demanda positiva

α : constante de suavizado

El método actualiza los pronósticos para el tamaño y el intervalo de la demanda solo después de que se produce una demanda positiva. Es decir, si en un período t la demanda es cero, el método solo incrementa el recuento de períodos de tiempo desde la última demanda positiva. El procedimiento para el método de Croston se describe a continuación:

Si $z_t = 0$, entonces

$$\hat{Z}_t = \hat{Z}_{t-1},$$

$$\hat{P}_t = \hat{P}_{t-1},$$

$$q = q + 1,$$

otro

$$\hat{Z}_t = \hat{Z}_{t-1} + \alpha(z_t - \hat{Z}_{t-1}),$$

$$\hat{P}_t = \hat{P}_{t-1} + \alpha(q - \hat{P}_{t-1}),$$

$$q = 1.$$

Combinar estos pronósticos proporciona la ecuación 3.

$$z^* = \frac{\hat{Z}_t}{\hat{P}_t} \quad (3)$$

Muchos investigadores propusieron correcciones al método de Croston para abordar los sesgos de pronóstico o proporcionar diferentes medios para estimar la ocurrencia de la demanda. Syntetos y Boylan (2005) propusieron una modificación al método de Croston, conocida como Aproximación Syntetos-Boylan (SBA), para evitar una correlación positiva entre el tamaño de la demanda pronosticada y la constante de suavizado, la corrección se realiza a través de la ecuación 4.

$$z^* = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{z}_t}{\hat{p}_t} \quad (4)$$

Otro enfoque que se ha propuesto en el pronóstico de la demanda intermitente es el método (ADIDA: Aggregate – Disaggregate Intermittent Demand Approach), que considera agregar la demanda en 'grupos de tiempo' de menor frecuencia, reduciendo así la presencia de observaciones cero (Nikolopoulos, Syntetos, Boylan, Petropoulos y Assimakopoulos, 2011). El método considera un proceso de tres etapas: (i) realizar una agregación de series de tiempo (ya sea una agregación superpuesta o no superpuesta), (ii) pronosticar el valor de la siguiente serie de tiempo sobre la serie de tiempo agregada, y (iii) desagregar el valor pronosticado a la agregación original (Rožanec y Mladenec, 2021). Petropoulos, Kourentzes y Nikolopoulos (2016) proponen un nuevo marco de agregación para el pronóstico de la demanda intermitente que realiza una agregación sobre los volúmenes de demanda, en contraste con el marco estándar que emplea una agregación temporal (a lo largo del tiempo), para lograr lo anterior se construye una serie de tiempo transformada, la serie de demanda intermitente inversa, mediante la descomposición de Croston.

Medidas de desempeño. Una previsión inadecuada tiene impactos económicos negativos en las empresas, el riesgo de una mala planificación puede provocar el incumplimiento de los requisitos del cliente y generar desconfianza e incluso pérdida de este. Esto no significa que las empresas deban basar todas sus decisiones en pronósticos, sin embargo, si pueden ser tomados como herramientas para que las organizaciones reaccionen eficazmente ante cambios imprevistos, garantizando el mejor desempeño de su organización (Csorba, 2007). Pinçe, Turrini y Meissner (2021) muestran en su estudio de 44 ítems que una gran mayoría utiliza medidas de precisión absoluta, porque son medidas simples e intuitivas y hay más opciones para medidas absolutas que para medidas relativas u otro tipo de medidas. Las medidas clásicas como error porcentual absoluto (MAPE), error cuadrático medio (MSE) y

error absoluto medio (MAE) siguen siendo las medidas de precisión más utilizadas, a pesar de las críticas sobre su idoneidad para la demanda intermitente a lo largo de los años.

MATERIALES Y MÉTODOS

El estudio se realiza a un conjunto de 14,895 series temporales correspondientes a la demanda mensual de empresas mexicanas de autopartes; enfocadas al ensamble y venta a nivel nacional e internacional (el historial mensual de demanda va de 16 a 60 datos).

Dado el número de series y de acuerdo con las empresas involucradas, se decidió realizar una primera segregación de los datos, utilizando el análisis ABC descrito en Silver et al. (2017) seleccionando las series con mayor volumen de ventas y demanda, es decir, utilizando solo aquellos datos que están con categoría A.

Un segundo análisis corresponde al comportamiento que presenta la demanda de estas series, a través del método propuesto por Syntetos et al. (2005) y utilizando las ecuaciones 1 y 2, cada serie se clasifica dentro de los cuatro patrones de demanda: errática, suave, irregular e intermitente.

El pronóstico de la demanda se realizó aplicando métodos de pronóstico como media móvil (MA por sus siglas en inglés), Winters, descomposición multiplicativa, ARIMA (Box-Jenkins), Croston y Aproximación Syntetos-Boylan (SBA por sus siglas en inglés). Para los métodos MA, Winters y ARIMA, se utilizó el software Minitab Inc. (2018) para el cálculo y Excel en descomposición multiplicativa, Croston y SBA. El desempeño de cada método fue evaluado a través del MAPE y MSE, a pesar de que en la literatura no se recomienda utilizar MAPE en caso de demanda intermitente porque produce valores infinitos o indefinidos para valores reales cero o cercanos a cero (Kourentzes, 2014; Kim y Kim 2016; Willemain et al., 2004) se decidió utilizarlo por dos razones; la primera es una medida de fácil interpretación al ser un valor porcentual y la segunda, se observaron series de tiempo sin demanda cero.

RESULTADOS

En la tabla 2 se muestran los resultados del análisis ABC de 14895 SKU, donde el 80% de su demanda y volumen de ventas están representados por 312 SKU.

Tabla 2
Resultados del análisis ABC

Análisis ABC	Cantidad de SKU	Porcentaje
Group A	312	2.10%
Group B	647	4.34%
Group C	13,936	93.56%

Fuente: Elaboración propia.

El segundo análisis corresponde a la clasificación de patrones de demanda, para esta clasificación solo se utilizan los 312 SKU que pertenecen al grupo A del análisis ABC. El resultado se describe en la tabla 3.

Tabla 3
Clasificación de patrones de demanda

Patrones de demanda	Cantidad de SKU	Porcentaje
Errática	60	19.23%
Granulada o irregular	37	11.86%
Suave	201	64.42%
Intermitente	14	4.49%

Fuente: Elaboración propia.

De acuerdo a los patrones propuestos por Syntetos et al. (2005) se observa que la mayoría de los SKU se encuentran dentro de la categoría suave con un 64.42%, mostrando que en estas series tanto la variabilidad en el tamaño de la demanda como el periodo entre dos demandas distintas de cero es baja; con 19.23% se encuentra el patrón errático en segundo lugar, exponiendo que la variabilidad del tamaño de la demanda es alta, el tercer y cuarto lugar lo ocupan los patrones irregulares e intermitentes, respectivamente, indicando alta variabilidad en el tamaño de la demanda al igual que en los periodos entre dos demandas distintas de cero.

Una de las preguntas más comunes sobre los pronósticos es ¿cuántos datos necesito? La respuesta según Hyndman y Kostenko (2007) "tanto como sea posible", porque cuantos más datos tengamos, mejor podremos identificar la estructura y los patrones utilizados para pronosticar. La tarea de pronosticar es predecir el futuro con la mayor precisión posible, dada toda la información disponible, incluidos datos históricos (Hyndman y Athanasopoulos, 2018); en este contexto y teniendo en cuenta que los datos de demanda mensual van de 16 a 60 meses, se decide considerar solo aquellos SKU con 60 datos,

dejando fuera del siguiente análisis los patrones irregular e intermitente, además de reducir el número de SKU a 207. Después de esta reducción el mayor peso aún sigue estando en el patrón suave (ver tabla 4).

Tabla 4
Clasificación final de los patrones de demanda

Patrones de demanda	de Cantidad de SKUs	Porcentaje
Errática	35	17%
Suave	172	83%

Fuente: Elaboración propia.

Syntetos et al. (2005) proponen el uso del método SBA para patrones de demanda erráticos, irregulares e intermitentes y Croston para patrones suaves, además de mencionar que se recomiendan valores en el rango de 0.05 a 0.2 para la constante de suavizado en el contexto de demanda intermitente. Por otro lado, Petropoulos et al. (2016) proponen un intervalo de 0.05 a 0.3 y Heizer y Render (2009) de 0.05 a 0.5. Considerando las recomendaciones de los autores sobre los rangos de la constante de suavizado, para este trabajo se utilizaron los valores de 0.01, 0.05, 0.1, 0.15, 0.2 y 0.5 para dicha constante, seleccionando el valor que muestre mejor desempeño de MAPE Y MSE. La figura 1 y 2 muestra gráficamente el comportamiento de las demandas errática y suave de la serie analizada



Figura 1. Gráfica de comportamiento de demanda errática.

Fuente: Elaboración propia.

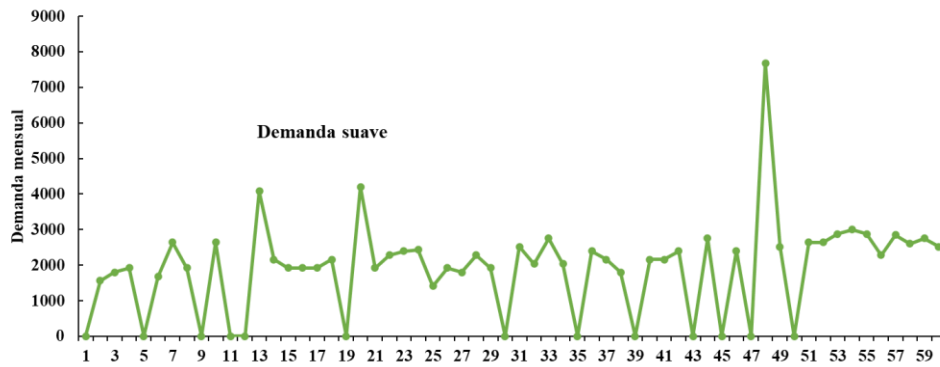


Figura 2. Gráfica de comportamiento de demanda suave.
 Fuente: Elaboración propia.

La tabla 5 muestra los resultados de las medidas de desempeño MAPE y MSE obtenidas en cada método de pronóstico aplicado a las demandas de autopartes.

Tabla 5
 Medidas de desempeño para los métodos aplicados

Patrones de demanda	de	Método	MAPE	MSE
Errática		SBA	57.52%	24459.99
		MA	0	0
		Winters	55.61%	0
		Descomposición	46.10%	0
		ARIMA	15.33%	99330.73
Suave		Croston	29.11%	2259968.21
		MA	42.53%	0
		Winters	45.83%	0
		Descomposición	25.25%	0
		ARIMA	18.93%	41694.68

Fuente: Elaboración propia.

Tomando en cuenta las recomendaciones de Frechtling (1996), que considera valores de MAPE entre 10% y 20% como un pronóstico “bueno”, y aceptable entre 20% y 30%, observamos que la mayoría de los valores de MAPE de la tabla 5 están fuera de este criterio por lo que se decide buscar una alternativa que mejore el desempeño de los métodos aplicados. Considerando la propuesta de Montanero (2008) de utilizar transformaciones matemáticas para obtener un ajuste satisfactorio a una distribución normal o, al menos, simétrica como herramienta que permite mejorar la precisión de las predicciones.

Los métodos de transformación Box-Cox o Ln son una familia de transformaciones potenciales utilizadas en estadística para corregir sesgos en la distribución de errores (Box y

Cox, 1964; Ortiz y Gil, 2014). Mediante la transformación de datos y aplicando nuevamente los métodos de pronóstico, los resultados obtenidos se muestran en la tabla 6.

Table 6
Desempeño de MAPE para datos transformados

Patrones de demanda	Método	MAPE
Errática	SBA	18.88%
	Descomposición	10.52%
Suave	Croston	17.14%
	MA	12.38%
	Descomposición	9.49%

Fuente: Elaboración propia.

DISCUSIÓN

Se analizó el conjunto de datos de las empresas mexicanas de autopartes y se categorizaron en los cuatro patrones de demanda intermitente (suave, errática, intermitente e irregular), aunque el análisis se hizo en series de tiempo para cada uno de los cuatro patrones ya mencionados, la mayor participación fue el patrón suave con un 64.42% que confirma una demanda regular en el tiempo y poca variabilidad en la cantidad demandada.

De acuerdo con los resultados mostrados en la tabla 5, para el patrón de demanda suave el método ARIMA tiene el mejor desempeño con un valor MAPE y MSE más bajos series sin valores de demanda nulos y series con valores de demanda nulos, respectivamente. En el caso del patrón errático, no existe coincidencia entre el método con mejor desempeño; para datos sin demanda nula se selecciona el método ARIMA y en datos con demanda nula la aproximación SBA es superior.

En la tabla 6 se muestra que, a través de la transformación de los datos, los valores de MAPE disminuyen a niveles menores al 20%, pero también cambió el método de pronóstico con mejor desempeño; en el patrón errático, el mejor desempeño se encontró en el método de descomposición, seguido de la aproximación SBA. Para el patrón suave, los métodos clásicos como la descomposición y la media móvil fueron los mejor clasificados, seguidos de Croston. En general, el patrón errático bajó de 43.64% a 14.70% y el suave de 32.33% a 13.00%, tomando en consideración el promedio como base de todas las series, dado que la fórmula para el cálculo del MAPE es igual para todos los métodos.

Mediante un análisis de proporciones se encontró que el 64% de los datos correspondientes al patrón suave fueron transformados con alguna de las familias pertenecientes a Box-Cox, en el caso del patrón errático solo al 8% se le aplicó algún tipo de transformación; considerando estas proporciones y para demostrar la independencia de que la cantidad de datos transformados dependía del patrón de demanda (Walpole, Myers, Myers, y Ye, 2012) se formula una prueba de independencia a través de la siguiente hipótesis:

H_0 : El tipo de datos utilizados (originales o transformados) para encontrar un buen MAPE (<20%) es independiente del patrón de demanda que muestren.

Con un nivel de significancia de $\alpha = 0.05$ y aplicando la prueba χ^2 correspondiente, se tomó la decisión de rechazar la hipótesis nula, concluyendo que existe suficiente evidencia estadística para inferir que la hipótesis nula es falsa, por lo que los datos utilizados para encontrar un buen MAPE no son independientes del patrón de demanda.

CONCLUSIONES

La comparación de los métodos tradicionales de pronóstico como el promedio móvil, Winters, descomposición multiplicativa y ARIMA contra dos de los métodos más aplicados (aproximación de Crostón y Syntetos-Boylan) para la demanda intermitente se realizó a través de la media del error cuadrático (MSE) y el error porcentual absoluto medio (MAPE) concluyendo que los modelos ARIMA tuvieron el mejor desempeño para datos sin transformación; sin embargo, la mayoría de las series tuvieron valores fuera de las consideraciones de un buen pronóstico (<20%) y buscando una herramienta que ayudara a mejorar estos resultados se aplicó el método Box-Cox, que redujo en un 40.22% el MAPE de los datos considerados en el patrón suave y 33.68% en el patrón errático; en ambos casos el método con mejor desempeño fue la descomposición multiplicativa, sin dejar de lado los métodos de Croston y SBA. La aplicación de los diferentes métodos de pronósticos sustentados por la literatura, demuestran la importancia que tiene la selección adecuada del método de pronóstico a aplicar para la determinación de la demanda con base en un detallado análisis del comportamiento de sus datos, utilizando parámetros establecidos por expertos y los resultados generados en el desarrollo del trabajo.

Los resultados obtenidos en esta investigación permiten al personal que desarrolla las actividades de pronósticos de demanda en la industria de autopartes, contar con elementos para la toma de decisiones en cuanto a la gestión de sus pronósticos

permitiendo contribuir a todos los eslabones de la cadena de suministro. Además, contar con datos confiables proporciona una cadena sólida para buscar siempre la máxima eficiencia en las operaciones y favorecer una respuesta rápida al menor costo. Por otro lado, este trabajo muestra cómo manejar la demanda en datos continuos, sin embargo, de acuerdo con el comportamiento de la demanda futuras investigaciones podrían centrarse en mejorar sus pronósticos a través de modelos que propongan actualizar la probabilidad de la demanda en lugar de la demanda de intervalos.

Finalmente, se demuestra que la aplicación de métodos de pronóstico para la determinación de la demanda, considerando parámetros adecuados, aseguran un desempeño confiable a los tomadores de decisiones y ventajas competitivas a cualquier sector productivo que los utilice.

Agradecimientos

Esta investigación fue apoyada por el Consejo Mexiquense de Ciencia y Tecnología (COMECYT), con el número de folio EESP2021-0060 en colaboración con la Universidad Autónoma del Estado de México, Secretaría de Investigación y Estudios Avanzados a través del Proyecto de investigación 5024-2020CIB.

REFERENCIAS

- Alalawin, A., Arabiyat, L. M., Alalaween, W., Qamar, A., y Mukattash, A. (2021). Forecasting vehicle's spare parts price and demand. *Journal of Quality in Maintenance Engineering*, 27(3), 483–499. doi: 10.1108/JQME-03-2020-0019
- Altay, N., Rudisill, F., y Litteral, L. (2008). Adapting Wright's modification of Holt's method to forecasting intermittent demand. *International Journal of Production Economics*, 111, 389–408. doi: 10.1016/j.ijpe.2007.01.009
- Anderson, D.R., Sweeney, D. J., y Williams, T. A. (2008). *Estadística para Administración y Economía* (10. ed.). Cengage Learning Latin America Editorial.
- Axsäter, S. (2006). *Inventory Control* (3. ed). New York: Springer Science.
- Balderas, S. N. (2021). Industria de autopartes, con potencial para crecer más de 35% después de la crisis. *Transportes y Turismo*. Recuperado de: <https://www.tyt.com.mx/nota/industria-de-autopartes-con-potencial-para-crecer-mas-de-35-despues-de-la-crisis>
- Box, G. E. P. y Cox, D. R. (1964). An Analysis of Transformations. *Journal of the Royal Statistical Society, Series B*, 26(2), 211–252. Recuperado de:

<http://www.jstor.org/stable/2984418>

- Boylan, J.E. y Syntetos, A. A. (2007). *Forecasting for Inventory Management of Service Parts*. *Complex System Maintenance Handbook*, 20. doi: 10.1007/978-1-84800-011-7
- Bucher, D. y Meissner, J. (2011). Configuring Single-Echelon Systems Using Demand Categorization. *Service Parts Management*, 203–219. London: Springer
- Chapman, S. N. (2006). *Planificación y Control de la producción*. México: Pearson.
- Chatras, C., Giard, V., y Sali, M. (2015). High variety impacts on Master Production Schedule: a case study from the automotive industry. *IFAC-PapersOnLine*, 48(3) 1073–1078. doi: 10.1016/j.ifacol.2015.06.226
- Chopra, S. y Meindl, P. (2008). *Administración de la Cadena de Suministro* (4.ed). México: Pearson.
- Costantino, F., Di Gravio, D., Patriarca, R., y Petrella, L. (2017). *Spare parts management for irregular demand items*. Omega Editorial. doi: 10.1016/j.omega.2017.09.009
- Croston, J. D. (1972). Forecasting and stock control for intermittent demands. *Journal of Operational Research Society*, 23(3), 289–303.
- Csorba, I. (2007). The Forecast-Centric Enterprise. *Journal Business Forecasting*, 26(2), 23.
- Diaz, D. A. B., Hennequin, S., y Roy, D. (2020). *Spare Parts Management in the Automotive Industry Considering Sustainability*. *Optimization of Complex Systems: Theory, Models, Algorithms and Applications*. *Advances in Intelligent Systems and Computing*, (1 ed.) vol. 991, Le Thi, H., Le, H., y Pham Dinh, T., Eds. Springer, Cham: 1109–1118.
- Do Rego, J.R. y De Mesquita, M.A. (2015). Demand forecasting and inventory control: A simulation study on automotive spare parts. *International Journal of Production Economics*, 161,1–16. doi: 10.1016/j.ijpe.2014.11.009
- Eaves, A. y Kingsman, B. (2004). Forecasting for the ordering and stock-holding of spare parts. *Journal of the Operational Research Society*, 55(4), 431–437. doi: 10.1057/palgrave.jors.2601697
- Engelmeyer, T. (2016). Demand Classification. *Engelmeyer, T Managing Intermittent Demand*, 63–72. Springer Gabler, Wiesbaden. doi: 10.1007/978-3-658-14062-5-4
- Frechtling, D. C. (1996). *Practical tourism forecasting*. Oxford; Boston: Butterworth-Heinemann.
- Ghobbar, A. y Friend, C. (2003). "Evaluation of forecasting methods for intermittent parts demand in the field of aviation: A predictive model. *Computing Operation*

Research, 30(14), 2097–2114. doi:10.1016/S0305-0548(02)00125-9

- Hellingrath, B. y Cordes, A.K. (2014). Conceptual approach for integrating condition monitoring information and spare parts forecasting methods, *Production & Manufacturing Research*, 2(1), 725–737. doi: 10.1080/21693277.2014.943431
- Hu, Q., Boylan, J. E., Chen, H., y Labib, A. (2017). OR in spare parts management: A review. *European Journal of Operation Research*, 266(2), 395-414. doi: 10.1016/j.ejor.2017.07.058
- Hua, Z., Zhang, B., Yang, J., y Tan, D. S. (2007). A new approach of forecasting intermittent demand for spare parts inventories in the process industries. *Journal of the Operational Research Society*, 58, 52–61. doi: 10.1057/palgrave.jors.2602119
- Hyndman, R. J. y Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2. ed), OTexts: Melbourne, Australia.
- Hyndman, R. y Kostenko, A. (2007). Minimum Sample Size Requirements for Seasonal Forecasting Models. *Foresight International Journal Application Forecasting*, 6, 12–15.
- Industria Nacional de Autopartes, A. C. [INA]. (2018). Diálogo con la industria automotriz 2018-2024". Agenda Automotriz. Versión 2018. Recuperado de: https://www.amda.mx/wp-content/uploads/asociaciones_2018-2024_180724.pdf
- Johnston, F.R. y Boylan, J. E. (1996). Forecasting for Items with Intermittent Demand. *Journal of the Operational Research Society*, 47(1), 113–121. doi: 10.1057/jors.1996.10
- Kim, S. y Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3), 669–679. doi:10.1016/j.ijforecast.2015.12.003
- Kourentzes, N. (2014). On intermittent demand model optimisation and selection. *International Journal of Production Economics*, 156, 180–190. doi: 10.1016/j.ijpe.2014.06.007
- Kumar, P., Herbert, M., y Rao, S. (2015). *Artificial Neural Network Approach To Industrial Demand Forecast*. in Proceeding of 23rd The IIER International Conference Singapore, April, 25, 43–47.
- Lindsey, M. y Pavur, R. (2008). A comparison of methods for forecasting intermittent demand with increasing or decreasing probability of demand occurrences. *Advances in Business and Management Forecasting*, 5, K. D. Lawrence and M. D. Geurts, Eds. Emerald Group Publishing Limited: 115–132.
- Mehdizadeh, M. (2020). Integrating ABC analysis and rough set theory to control the inventories of distributor in the supply chain of auto spare parts. *Computers & Industrial Engineering*, 139. doi: 10.1016/j.cie.2019.01.047

- Minitab Inc. (2018). Minitab 18 Statistical Software. State College, Pennsylvania.
- Montanero Fernández, J. (2008). Modelos Lineales, 56. UEX.
- Nikolopoulos, K., Syntetos, A., Boylan, J., Petropoulos, F., y Assimakopoulos, V. (2011). An Aggregate-Disaggregate Intermittent Demand Approach (ADIDA) to Forecasting: An Empirical Proposition and Analysis. *Journal of the Operational Research Society*, 62(3), 544–554. doi: 10.1057/jors.2010.32
- Ortiz, P.J. y Gil, D. (2014). Transformaciones logarítmicas en regresión simple. *Comunicaciones en Estadística*, 7(1), 80–98. doi:10.15332/s2027-3355.2014.0001.06
- Pennings, C.L.P., Van Dalen, J., y Van Der Laan, E. A. (2007). Exploiting elapsed time for managing intermittent demand for spare parts. *European Journal Operation Research*, 258(3), 958–969. doi: 10.1016/j.ejor.2016.09.017
- Petropoulos, F., Kourentzes, N., y Nikolopoulos, K. (2016). Another look at estimators for intermittent demand.," *International Journal of Production Economics*, Part A: 18, 154–161. doi: 10.1016/j.ijpe.2016.04.017
- Pinçe, Ç., Turrini, L., y Meissner, J. (2021). Intermittent demand forecasting for spare parts: A Critical review. *Omega*, 105, 102513. doi: 10.1016/j.omega.2021.102513
- Ravindran, A.R. y Warsing Jr., D. P. (2013). *Supply Chain Engineering: Models and Applications*, (1. ed.), Boca Raton, FL: Press, CRC.
- Ravindran, A.R. (2008). *Operations Research and Management Science Handbook*. Boca Raton, FL: Taylor & Francis Group.
- Romeijnnders, W., Teunter, R., y Van Jaarsveld, W. (2012). A two-step method for forecasting spare parts demand using information on component repairs. *European Journal of Operation Research*, 220(2), 386–393. doi: 10.1016/j.ejor.2012.01.019
- Rožanec, J. M. y Mladenec, D. (2021). Reframing demand forecasting: a two-fold approach for lumpy and intermittent demand. *ArXiv*, abs/2103.1. doi: 10.1016/s1537-1891(09)00089-5
- Şahin, M., Kızılaslan, R., y Demirel, Ö. F. (2013). Forecasting Aviation Spare Parts Demand Using Croston Based Methods and Artificial Neural Networks. *Journal of Social Economics Research*, 15(2) 1–21.
- Silver, E. A., Pyke, D. F., y Thomas, D. J. (2017). *Inventory and production Management in Supply Chains*, Fourth. Boca Raton, FL: Taylor & Francis Group.
- Syntetos, A. A. y Boylan, J. E. (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), 303–314. doi: 10.1016/j.ijforecast.2004.10.001
- Syntetos, A., Boylan J.E., y Croston, J. (2005). On the categorization of demand

patterns. *Journal of Social Economics Research*, 56, 495–503. doi: 10.1057/palgrave.jors.2601841

- Syntetos, A.A., Babai, M.Z., & Altay, N. (2012). On the demand distributions of spare parts. *Journal of Social Economics Research*, 50(8), 2101–2117. doi: 10.1080/00207543.2011.562561.
- Teunter, R. H., y Duncan, L. (2009). Forecasting intermittent demand: a comparative study. *Journal of Social Economics Research*, 60(3), 321–329. doi: 10.1057/palgrave.jors.2602569.
- Teunter, R.H., Syntetos, A. A., y Babai, M. Z. (2011). Intermittent demand: Linking forecasting to inventory obsolescence. *European Journal of Operation Research*, 214(3), 606–615. doi: 10.1016/j.ejor.2011.05.018
- Van Der Auweraer, S., Boute, R. N., y Syntetos, A. A. (2019). Forecasting spare part demand with installed base information: A review. *International Journal of Forecasting*, 35(1), 181–196. doi: 10.1016/j.ijforecast.2018.09.002.
- Vasumathi, B. y Saradha, A. (2013). Forecasting Intermittent Demand for Spare Parts. *International Journal of Computer Applications*, 75(11), 12–16. doi: 10.5120/13154-0805.
- Walpole, R. E., Myers, R. H., Myers, S. L., y Ye, K. (2012). *Probabilidad y estadística para ingeniería y ciencias*. México: Pearson.
- Willemain, T.R., Smart, C. N., y Schwarz, H. F. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of Forecasting*, 20(3), 375–387. doi: 10.1016/S0169-2070(03)00013-X.
- Williams, T.M. (1984). Stock Control with Sporadic and Slow-Moving Demand. *Journal of Social Economics Research*, 35, 939–948. doi: 10.1057/jors.1984.185.
- Xu, Q., N. Wang, y Shi, H. (2012). Review of Croston's method for intermittent demand forecasting. 2012 9th International Conference on Fuzzy Systems and Knowledge Discovery: 1456–1460. doi:10.1109/FSKD.2012.6234258.