

COMPARACIÓN DE PRONÓSTICOS CON DEMANDA INTERMITENTE EN UNA EMPRESA DE EMPAQUES DE PLÁSTICO

ALEX VÍCTOR SÁNCHEZ GARCÍA

<https://orcid.org/0000-0002-2847-5791>

Universidad de Lima, Facultad de Ingeniería, Lima, Perú

JOSÉ ANTONIO TAQUÍA GUTIÉRREZ*

<https://orcid.org/0000-0002-1711-6603>

Universidad de Lima, Facultad de Ingeniería, Lima, Perú

Recibido: 13 de octubre del 2023 / Aceptado: 17 de octubre del 2023

doi: <https://doi.org/10.26439/ing.ind2024.n.6715>

RESUMEN. En el presente artículo se comparan tres métodos de pronósticos de demanda, aplicados en una empresa peruana productora de envases de plástico para el sector cosmético con demanda intermitente. Los métodos comparados fueron Croston, Croston TSB y suavizamiento exponencial. Las métricas de error que se usaron y compararon para realizar los pronósticos fueron el error medio absoluto, el error porcentual medio y el error cuadrático medio. Se observó que el modelo de Croston TSB obtuvo un mejor rendimiento que los otros dos, con un error menor a 20 % contra la venta real.

PALABRAS CLAVE: envases de plástico / cadena de suministro / aprendizaje automático / previsión de ventas / oferta y demanda / suavizamiento exponencial / prospectiva

Este estudio no fue financiado por ninguna entidad.

* Autor corresponsal.

Correos electrónicos en orden de aparición: 20162521@aloe.ulima.edu.pe; Jtaquia@ulima.edu.pe

Este es un artículo de acceso abierto, distribuido bajo los términos de la licencia Creative Commons Attribution 4.0 International (CC BY 4.0).

MACHINE LEARNING APPLIED TO FORECAST INTERMITTENT DEMAND IN A PLASTIC PACKAGING COMPANY

ABSTRACT. This article compares three demand forecasting methods applied to a Peruvian cosmetic plastic packaging company with intermittent demand. The comparison between the error metrics for forecasting Mean Absolute Error, Mean Percentage Error, and Mean Squared Error obtained by the Croston, Croston TSB, and Exponential Smoothing methods showed that the Croston TSB model outperformed the other two, with an error of less than 20 % compared to actual sales.

KEYWORDS: plastic containers / supply chain / machine learning / sales forecasting / supply and demand / exponential smoothing / forecasting

1. INTRODUCCIÓN

La gestión de operaciones en una empresa de consumo masivo requiere pronosticar con la mayor precisión posible los cambios de la demanda (Nikolopoulos et al., 2016), debido a que la demanda futura influye en la planificación de la producción y la gestión de inventarios. Además, el pronóstico de la demanda es crucial en la cadena de abastecimiento, tanto para la satisfacción del cliente como para el rendimiento financiero.

Usualmente, para calcular la cantidad de pedidos solo se requieren pronósticos generados con la demanda promedio por periodo; esto afecta el inventario y se tiene que calcular con parámetros de desviación estándar para los cuales se asume que no cambian con el tiempo (Willemain et al., 2004). Sin embargo, existen casos en que la demanda es esporádica o intermitente, lo que obliga a que la gestión de inventarios considere restricciones de tiempos de reabastecimiento de proveedores y asignación adecuada de espacios de almacenamiento que cambian periódicamente (Sharma et al., 2021).

Croston (1972), afirma que la demanda intermitente, puede aumentar el nivel de reposición de existencias y sesgar las estimaciones de la demanda media. Además, puede haber niveles de *stock* y, en estos casos, aumentan de manera considerable los costos de producción, almacenamiento, procesamiento de pedidos y entregas.

Pronosticar erróneamente la demanda trae consigo diferentes problemas, entre ellos la sobrestimación, es decir, una situación en que los registros de consumo de ventas para varios productos que se habían mantenido estables durante un periodo de tiempo, presentan existencias en almacén más altas que la demanda máxima que habían requerido para cumplir con la venta.

Uno de los sectores que más ha incorporado la incertidumbre en la gestión de demanda es el sector de manufactura, lo que ha provocado el desarrollo de muchos métodos y técnicas de pronóstico (Gutiérrez et al., 2008), aunque hay que tomar en cuenta que la demanda intermitente también se observa con frecuencia en otros rubros como los negocios de repuestos, maquinaria industrial, etcétera. En todos estos sectores se constata que es muy difícil predecir con precisión la demanda intermitente con las técnicas de pronóstico tradicionales como promedios móviles o suavización simple (Altay et al., 2008).

Entre los aportes de la academia al sector industrial está el diseño de métodos de pronóstico adaptados de un enfoque de serie de tiempo con autocorrelación (Kourentzes, 2013). Entre estos enfoques tenemos el suavizamiento exponencial, el método de Croston Syntetos y la aproximación de Boylan (Syntetos & Boylan, 2001) y, más recientemente, el método Teunter, Syntetos y Babai. Es importante para el adecuado funcionamiento de los métodos de pronóstico de la demanda intermitente que, por la naturaleza incierta de esta, incorporen la idea de recurrencia para hacer más robusta la proyección (Prak et al., 2017).

Ante lo expuesto, la pregunta de investigación para el presente artículo es: ¿cuál de las técnicas se desempeña mejor como método de pronóstico ante una demanda intermitente?

La estructura del artículo es la siguiente: en la sección de métodos, se dará mayores detalles de la metodología a emplear y los datos utilizados; a continuación, se expondrán los resultados experimentales producto del estudio y, finalmente, en la parte de discusión y conclusiones, se analizarán los resultados obtenidos, se discutirá su significado y alcance, y se los comparará con resultados de referencias internacionales.


2. METODOLOGÍA

La presente investigación tiene un enfoque cuantitativo, de diseño no experimental, de tipo descriptivo. Se utilizó la base de datos de PIERIPLAST SAC, una empresa proveedora de empaques para el sector de higiene y cuidado personal del rubro de cosméticos, líder en el mercado, con una facturación anual de US\$ 30 millones.

En la Figura 1 se muestra la gráfica de la metodología empleada para el presente trabajo de investigación.

Figura 1

Esquema de trabajo



Suavizamiento exponencial

Suavizamiento exponencial simple, o SES por su abreviatura en inglés, es un método de pronóstico de series de tiempo univariadas; es decir, el análisis está basado en una sola variable. Este parámetro, llamado alfa (α) y también conocido como factor de suavizado o coeficiente de suavizado, controla la influencia de las observaciones de períodos anteriores. Alfa se establece en un valor entre 0 y 1. Si alfa presenta un valor alto, indica que el modelo presta atención a las observaciones pasadas más recientes. Por otro lado, si el valor es bajo, significa que se tiene en cuenta una mayor parte del historial al hacer una predicción. Asimismo, el método de suavizamiento exponencial solo tiene en cuenta el tamaño de la demanda de cada periodo de tiempo (Yang et al., 2021). Para hallar el pronóstico se utiliza la siguiente fórmula:

$$\hat{D}t = \hat{D}(t-1) + \alpha (Dt - \hat{D}(t-1))$$

$\hat{D}t$: Es la demanda promedio estimada por periodo para el tiempo t+1 realizada en el momento t.

Dt : Es la demanda real de un artículo en el momento t.

α : Es un parámetro de suavizado que satisface $0 \leq \alpha \leq 1$

Método de Croston

Croston es el método estándar utilizado para pronosticar artículos de demanda intermitente (Babai et al., 2014). Particularmente, implica un suavizamiento exponencial simple separado del tamaño de la demanda y el periodo de tiempo entre demandas. Algunos de los términos para el procedimiento de Croston son los siguientes:

$\bar{T}t$: Es el intervalo de demanda estimado en el periodo t.

Tt : Es el intervalo de demanda observado en el periodo t.

α , Es un parámetro de suavizado que satisface $0 \leq \alpha \leq 1$

$\hat{z}t$: Es el tamaño de la demanda promedio estimado en el momento t.

Zt : Es el tamaño de la demanda observada en el momento t.

El método de Croston actualiza las previsiones de demanda para el tamaño y el intervalo de la demanda, luego de que hubiera una demanda positiva. Esto quiere decir que, si en un periodo t la demanda es cero, el método solo incrementa la cuenta de periodos de tiempo desde la última demanda positiva. El procedimiento se describe a continuación:

$$\hat{z}t = \hat{z}(t-1) + \alpha (Zt - \hat{z}(t-1))$$

$$\bar{T}t = \bar{T}(t-1) + \beta (Tt - \bar{T}(t-1))$$

Si $Dt > 0$, $\hat{z}t = \hat{z}(t-1)$ y $\bar{T}t = \bar{T}(t-1)$

Con el método de Croston, la demanda intermitente se pronostica determinando el volumen de demanda y el intervalo de demanda (Cheng et al., 2016), como se muestra a continuación:

$$\hat{D}t = \frac{\hat{z}t}{\bar{T}t}$$

Croston TSB

Al igual que los otros métodos de pronóstico, el método de Croston TSB también utiliza una estrategia de pronóstico para demanda intermitente. Esta es una modificación del método de Croston (Teunter & Sani, 2009).

Este reemplaza el intervalo de demanda en el método de Croston, por la probabilidad de demanda que se actualiza cada periodo. Por lo tanto, TSB puede utilizarse para abordar temas de obsolescencia, proporcionando previsiones actualizadas, incluso después de largos intervalos con demanda cero (Nikolopoulos et al., 2016; Prestwich et al., 2021). Haciendo una comparación con Croston, el método TSB no está sesgado y su pronóstico de probabilidad puede usarse para estimar el riesgo de obsolescencia. El modelo TSB utiliza un suavizamiento exponencial simple para separar la probabilidad y el tamaño de la demanda. La estimación de probabilidad se actualiza cada periodo, mientras que la estimación del tamaño solo se actualiza cuando la demanda es distinta de cero. El modelo se puede expresar en las siguientes fórmulas:

$$\hat{z}_t = \hat{z}(t-1) + \alpha (Z_t - \hat{z}(t-1))$$

$$\hat{p}_t = \hat{p}(t-1) + \beta(p_t - \hat{p}(t-1))$$

Si $D_t > 0$, $\hat{z}_t = \hat{z}(t-1)$ y $\hat{p}_t = \hat{p}(t-1) + \beta(0 - \hat{p}_t)$

$$\hat{D}_t = (\hat{p}_t)(\hat{z}_t)$$

\bar{T}_t : Es el intervalo de demanda estimado en el periodo t .

T_t : Es el intervalo de demanda observado en el periodo t .

α, β : Es un parámetro de suavizado que satisface $0 \leq \alpha \leq 1$

\hat{z}_t : Es el tamaño de la demanda promedio estimado en el momento t .

Z_t : Es el tamaño de la demanda observada en el momento t .

\hat{D}_t : Es la demanda promedio estimada por periodo para el tiempo $t+1$


p_t : Es la probabilidad de ocurrencia de la demanda en el tiempo real

\hat{p}_t : Es la probabilidad estimada de ocurrencia de la demanda

Se utilizó la data de 81 productos brindados por la empresa PIERIPLAST SAC, los cuales tienen periodos en los que no hay demanda. Con este universo total de datos, se hizo una gráfica de Pareto para escoger el producto o los productos que generan mayor impacto.

Figura 2

Gráfica de Pareto



Para el cálculo del tamaño de la muestra, se ha usado el método de población finita. Se ha tomado de la data histórica brindada por la empresa en estudio.

Si la población es finita, se conoce el total de la población, y con esto se desea saber cuál será el tamaño de la muestra a trabajar. Se aplicará la siguiente fórmula para calcular el valor de “n”.

$$n = \frac{N * Z^2 * p * q}{d^2 * (N - 1) + Z^2 * p * q}$$

Donde:

N = Total de la población (81 productos)

Z = 1,96 (si la seguridad es de 95 %)

p = Proporción esperada (en este caso 5 % = 0,05)

q = (1-p) En este caso (1-0,05 = 0,95)

d = Precisión (en la investigación se usará el 5 %)

Al aplicar la fórmula para calcular el tamaño de la muestra, nos arroja un total de 68 productos.

Para el cálculo del pronóstico de la demanda, se ha simulado mediante el lenguaje de programación Python, y se han obtenido valores tanto para el método de suavizamiento exponencial simple, el método de Croston y el método de Croston TSB.

Para aplicar el método de Croston TSB, se evaluaron tres puntos y criterios importantes:

- Periodicidad, que es la frecuencia con la que aparece, se realiza o se repite la demanda.

$$\text{Si } dt > 0, \text{ entonces, } p_{t+1} = \alpha q + (1 - \alpha)p_t$$

$$\text{Si } dt = 0, \text{ entonces, } p_{t+1} = p_t$$

- Nivel de demanda, que mide el impacto de la demanda y es importante porque ayuda a definir el nivel de inversión.

$$\text{Si } dt > 0, \text{ entonces, } a_{t+1} = \alpha dt + (1 - \alpha)a_t$$

$$\text{Si } dt = 0, \text{ entonces, } a_{t+1} = a_t$$

- Pronóstico

Para este trabajo se usará el método de Croston TSB, en el cual se multiplica la probabilidad estimada por el tamaño estimado de la demanda.

$$\hat{D}_t = (\hat{p}_t)(\hat{z}_t)$$


3. RESULTADOS

Se hizo una comparación entre el método de suavizamiento exponencial simple, el método de Croston y el método de Croston TSB, para determinar cuál de los tres métodos de pronóstico aplica mejor para trabajar con una demanda intermitente.

En la gráfica podemos observar cómo el método de Croston TSB presenta una variabilidad baja, en comparación con los otros dos métodos. Además, Croston TSB no está sesgado y su pronóstico de probabilidad puede usarse para estimar el riesgo de obsolescencia. Esto debido a que Croston TSB utiliza un suavizado exponencial único, separado para la probabilidad y el tamaño de la demanda.

Figura 3

Gráfico de pronósticos



Resultados numéricos

Para el cálculo de los errores se han realizado cuatro mediciones, usando los siguientes métodos de errores: ME (error medio), MAE (error absoluto medio), MAPE (error de porcentaje absoluto medio) y RMSE (error cuadrático medio).

A continuación, se muestran las siguientes fórmulas para los diferentes tipos de errores:

$$ME = \frac{\sum(Demanda\ real - Demanda\ pronóstico)}{n} \dots\dots\dots(1)$$

$$MAE = \frac{\sum/|Demanda\ real - Demanda\ pronóstico|}{n} \dots\dots\dots(2)$$

$$MAPE = \frac{\frac{\sum/|Demanda\ real - Demanda\ teórica|}{/Demanda\ real/}}{n} \dots\dots\dots(3)$$

$$RMSE = \sqrt{\frac{\sum(Demanda\ real - Demanda\ pronóstico)^2}{n}} \dots\dots\dots(4)$$

En la Tabla 1 pueden verse los resultados de los errores, para cada tipo de pronóstico.

Tabla 1

Comparación nivel de error

Método de pronóstico	ME	MAE	MAPE	RMSE
Suavizamiento	-16 166,97	42 616	51,20 %	56 063
Croston	- 4206,42	30 694	37,27 %	41 324
Croston TSB	921,69	25 530	19,47 %	36 589

En la Tabla 1 también se puede observar que, por cada tipo de error, el método de Croston TSB ofrece un mejor resultado.

El error medio es positivo (solo se puede observar esto en el método TSB), lo que quiere decir que la cantidad real es mayor a la cantidad pronosticada. Así también, presenta un menor MAE, el cual analiza en qué medida se equivoca en los pronósticos en promedio.

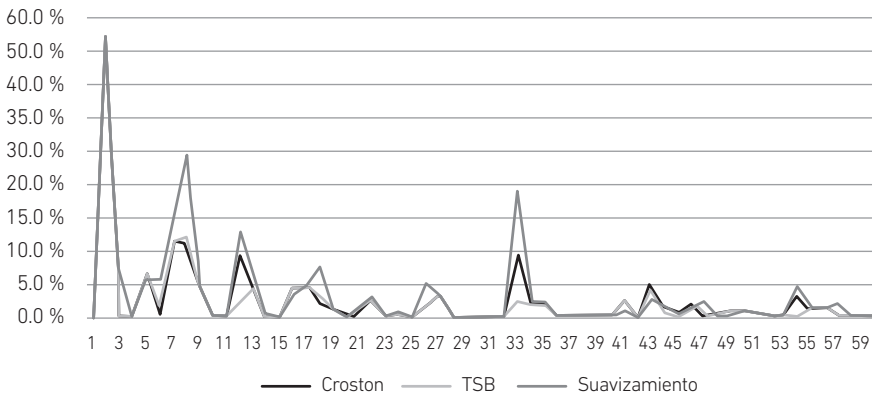
También se puede observar que presenta un menor MAPE (19,47 %) y cabe señalar que los valores del MAPE entre el 10 % y el 20 % son considerados como un buen pronóstico. Un MAPE entre el 20 % y el 30 % es aceptable.

Asimismo, se pudo evaluar el error con el método RMSE. Para el método TSB se obtuvo el menor nivel de error. Por ende, mientras menor sea el RMSE, mejor será el modelo y sus predicciones.

La diferencia con los otros métodos radica en que el modelo TSB realiza un seguimiento tanto en el nivel de la demanda como en la probabilidad de la demanda. Es por ello que genera un menor nivel de error. Como se observa en la Figura 4, el método de TSB genera un menor error (por debajo del 20 %), mientras que el método de SE llega a un pico de 50 %.

Figura 4

Nivel de error



4. DISCUSIÓN

En el presente artículo se compararon tres métodos de pronósticos. El que presentó menor nivel de error (comparando tanto el error medio, el error medio absoluto, el error porcentual medio absoluto y el error cuadrático medio), fue el método de Croston TSB. Así, pues, se ratifica lo señalado por Prestwich et al. (2021) en relación a que el método de suavización exponencial simple conduce a niveles de existencias inadecuados, debido a que hay una tendencia alcista al sesgo en el pronóstico en el periodo posterior a un valor con demanda diferente de cero. Es por ello que da un error negativo, lo que quiere decir que se está sobreestimando la demanda.

Por otro lado, Yang et al. (2021) proponen un nuevo método de pronóstico TSB modificado, en el cual comparan el EM y el RMSE como métodos de errores, y obtienen que el RMSE es menor en el método de TSB que en el método de SBA. En nuestro artículo se llega a la misma conclusión, puesto que el RMSE es menor para el método de Teunter que para el de Croston y el de suavización exponencial.

5. CONCLUSIONES

Una de las principales conclusiones del presente trabajo de investigación es que el método de Croston TSB nos da una mayor exactitud de la demanda al momento de hacer un pronóstico con demanda intermitente. Esto permite mejorar y aumentar la eficiencia de inventario, pues hace que los niveles de existencias tengan un margen mínimo y que los niveles de *stock* sean los adecuados.

Asimismo, el método de Croston TSB realiza un seguimiento al nivel de la demanda y también a la probabilidad de la demanda, mientras que Croston y el método de suavizamiento solo realizan un seguimiento del nivel (que incluye la idea de probabilidad de que se produzca la demanda).

6. REFERENCIAS

- Altay, N., Rudisill, F., & Litteral, L. A. (2008). Adapting Wright's modification of Holt's method to forecasting intermittent demand. *International Journal of Production Economics*, 111(2), 389–408. <https://doi.org/10.1016/j.ijpe.2007.01.009>
- Amirkolaii, K. N., Baboli, A., Shahzad, M. K., & Tonadre, R. (2017). Demand forecasting for irregular demands in business aircraft spare parts supply chains by using Artificial Intelligence (AI). *IFAC-PapersOnLine*, 50(1), 15221–15226. <https://doi.org/10.1016/j.ifacol.2017.08.2371>
- Babai, M. Z., Syntetos, A., & Teunter, R. (2014). Intermittent demand forecasting: An empirical study on accuracy and the risk of obsolescence. *International Journal of Production Economics*, 157(1), 212–219. <https://doi.org/10.1016/j.ijpe.2014.08.019>

- Cheng, C. Y., Chiang, K. L., & Chen, M. Y. (2016). Intermittent demand forecasting in a tertiary pediatric intensive care unit. *Journal of Medical Systems*, 40, Artículo 217. <https://doi.org/10.1007/S10916-016-0571-9>
- Croston, J. D. (1972). Forecasting and stock control for intermittent demands. *Operational Research Quarterly (1970-1977)*, 23(3), 289-303. <http://dx.doi.org/10.2307/3007885>
- Gutierrez, R. S., Solis, A. O., & Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural networks. *International Journal of Production Economics*, 111(2), 409-420. <https://doi.org/10.1016/j.ijpe.2007.01.007>
- Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143(1), 198-206. <https://doi.org/10.1016/j.ijpe.2013.01.009>
- Nikolopoulos, K. I., Babai, M. Z., & Bozos, K. (2016). Forecasting supply chain sporadic demand with nearest neighbor approaches. *International Journal of Production Economics*, 177, 139-148. <https://doi.org/10.1016/j.ijpe.2016.04.013>
- Petropoulos, F., & Kourentzes, N. (2015). Forecast combinations for intermittent demand. *Journal of the Operational Research Society*, 66(6), 914-924. <https://doi.org/10.1057/jors.2014.62>
- Prak, D., Teunter, R., & Syntetos, A. (2017). On the calculation of safety stocks when demand is forecasted. *European Journal of Operational Research*, 256(2), 454-461. <https://doi.org/10.1016/j.ejor.2016.06.035>
- Prestwich, S. D., Tarim, S. A., & Rossi, R. (2021). Intermittency and obsolescence: A Croston method with linear decay. *International Journal of Forecasting*, 37(2), 708-715. <https://doi.org/10.1016/j.ijforecast.2020.08.010>
- Sharma, M., Joshi, S., Luthra, S., & Kumar, A. (2021). Managing disruptions and risks amidst COVID-19 outbreaks: role of blockchain technology in developing resilient food supply chains. *Operations Management Research*, 15, 268-281. <https://doi.org/10.1007/s12063-021-00198-9>
- Syntetos, A. A., & Boylan, J. E. (2001). On the bias of intermittent demand estimates. *International journal of production economics*, 71(1-3), 457-466. [https://doi.org/10.1016/S0925-5273\(00\)00143-2](https://doi.org/10.1016/S0925-5273(00)00143-2)
- Teunter, R., & Sani, B. (2009). On the bias of Croston's forecasting method. *European Journal of Operational Research*, 194(1), 177-183. <https://doi.org/10.1016/j.ejor.2007.12.001>
- Willemain, T. R., Smart, C. N., & Schwarz, H. F. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of Forecasting*, 20(3), 375-387. [https://doi.org/10.1016/S0169-2070\(03\)00013-X](https://doi.org/10.1016/S0169-2070(03)00013-X)

Yang, Y., Ding, C., Lee, S., Yu, L., & Ma, F. (2021). A modified Teunter-Syntetos-Babai method for intermittent demand forecasting. *Journal of Management Science and Engineering*, 6(1), 53–63. <https://doi.org/10.1016/j.jmse.2021.02.008>

