

Pronóstico de la demanda en sistemas de producción MTS: Evaluación de modelos de series de tiempo y modelos matemáticos

Demand forecasting in MTS production systems: evaluation of time series and mathematical models

Johanna Graciela Briones Franco*
Universidad de Guayaquil
Guayaquil - Ecuador
johanna.brionesf@ug.edu.ec
<https://orcid.org/0000-0003-4659-5372>

Byron Daniel Erazo Rodríguez
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
erazodaniel97@gmail.com
<https://orcid.org/0009-0001-3339-9017>

Edison Hernán Morales Machado
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
edisonh.morales@espoch.edu.ec
<https://orcid.org/0009-0005-6590-7409>

Marco Antonio Santillán Tasigchana
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
santillan@espoch.edu.ec
<https://orcid.org/0009-0005-3248-0410>

*Correspondencia:
johanna.brionesf@ug.edu.ec

Cómo citar este artículo:
Briones, J., Erazo, B., Morales, E., & Santillán, M. (2026). Pronóstico de la demanda en sistemas de producción MTS: Evaluación de modelos de series de tiempo y modelos matemáticos. *Esprint Investigación*, 5(1), 1007-1021. <https://doi.org/10.61347/ei.v5i1.322>

Recibido: 13 de mayo de 2026

Aceptado: 17 de junio de 2026

Publicado: 22 de junio de 2026

Copyright: Derechos de autor 2026 Johanna Graciela Briones Franco, Byron Daniel Erazo Rodríguez, Edison Hernán Morales Machado, Marco Antonio Santillán Tasigchana.



Esta obra está bajo una licencia internacional Creative Commons Atribución-NonComercial 4.0.

Resumen: El pronóstico de la demanda constituye el primer eslabón de la planificación en los sistemas de producción Make-to-Stock, donde la fabricación se anticipa a los pedidos y un error de estimación se traduce en quiebres de inventario o en exceso de producto terminado. El objetivo de este estudio fue evaluar y comparar modelos de series de tiempo para el pronóstico de la demanda en un entorno de producción Make-to-Stock, con el fin de optimizar la planificación de la producción. Se comparó siete modelos de series de tiempo y suavizamiento (promedio móvil simple, promedio móvil ponderado, suavizamiento exponencial simple, método de Holt, Holt-Winters aditivo, Holt-Winters multiplicativo y descomposición) sobre la demanda mensual de una empresa industrial de producción en línea de bienes de consumo masivo, a lo largo de cuarenta y ocho meses. La serie se dividió en treinta y seis meses de entrenamiento y doce de validación, y el desempeño se midió mediante la desviación absoluta media, el error cuadrático medio, el error porcentual absoluto medio y la señal de rastreo. Los resultados mostraron una superioridad neta de los modelos que incorporan estacionalidad, con errores porcentuales cercanos al 2,4 %, frente a valores superiores al 7,8 % en los métodos que la ignoran. Aunque la descomposición alcanzó el menor error de magnitud, la señal de rastreo evidenció un sesgo de subestimación, por lo que se seleccionó Holt-Winters multiplicativo al combinar exactitud y ausencia de sesgo. Con este modelo se proyectó la demanda de 2026 como insumo para la planificación. El estudio confirma que los modelos clásicos, interpretables y de bajo costo computacional, resultan suficientes para sustentar decisiones de producción en contextos de demanda continua y estacional.

Palabras clave: Holt-Winters, Make-to-Stock, planificación de la producción, pronóstico de demanda, series de tiempo.

Abstract: Demand forecasting constitutes the first step in planning within Make-to-Stock production systems, where manufacturing is carried out in anticipation of orders and estimation errors result in stockouts or excess finished goods. The objective of this study was to evaluate and compare time series models for demand forecasting in a Make-to-Stock production environment, in order to optimize production planning. Seven time series and smoothing models were compared (simple moving average, weighted moving average, simple exponential smoothing, Holt's method, additive Holt-Winters, multiplicative Holt-Winters, and decomposition) using monthly demand data from a manufacturing company operating in a mass consumer goods production line over a period of forty-eight months. The series was divided into thirty-six months for training and twelve months for validation, and performance was measured using mean absolute deviation, mean squared error, mean absolute percentage error, and tracking signal. The results showed a clear superiority of models that incorporate seasonality, with percentage errors close to 2.4%, compared to values above 7.8% in methods that ignore it. Although decomposition achieved the lowest magnitude error, the tracking signal revealed a tendency toward underestimation; therefore, the multiplicative Holt-Winters model was selected, as it combined accuracy with the absence of bias. Using this model, demand for 2026 was forecast as input for production planning. The study confirms that classical, interpretable, and low-computational-cost models are sufficient to support production decision-making in contexts of continuous and seasonal demand.

Keywords: Demand forecasting, Holt-Winters, Make-to-Stock, production planning, time series.

1. Introducción

La función de producción en las empresas manufactureras contemporáneas se fundamenta en la capacidad de anticipar la demanda del mercado antes de que esta se materialice. En los sistemas de producción bajo la estrategia Make-to-Stock (MTS), esta capacidad no constituye únicamente una ventaja operativa, sino el eje central del sistema productivo. A diferencia de los modelos Make-to-Order, donde la producción se activa a partir de pedidos confirmados, el enfoque MTS implica una producción anticipada e independiente de la demanda específica, generando inventarios de producto terminado disponibles para satisfacer la demanda inmediata del consumidor. Esta lógica de producción basada en inventarios traslada la incertidumbre hacia el sistema productivo y asigna al pronóstico de demanda un rol crítico en el equilibrio entre sobreinventario y desabastecimiento (Kumar et al., 2024).

La vigencia de los modelos clásicos de pronóstico sigue siendo relevante. Diversos estudios han evaluado el suavizamiento exponencial de Holt-Winters frente a modelos autorregresivos integrados de media móvil en la gestión de inventarios, evidenciando que ambos enfoques mantienen un desempeño competitivo bajo distintas condiciones de estabilidad económica, dependiendo de las características de la serie analizada (Kumar et al., 2024). De manera complementaria, la evidencia en el sector energético muestra que los modelos de suavizamiento, combinados con técnicas de regresión, pueden alcanzar niveles de precisión comparables a enfoques más complejos (Rao et al., 2023).

En contraste, la última década ha evidenciado un crecimiento significativo de los enfoques basados en aprendizaje automático y aprendizaje profundo. Modelos como redes LSTM, máquinas de soporte vectorial, métodos de boosting y arquitecturas híbridas han sido aplicados con éxito en la predicción de demanda, especialmente en contextos con relaciones no lineales y patrones temporales complejos (Lei et al., 2025; Douaioui et al., 2024). Sin embargo, la literatura también señala que los modelos estadísticos clásicos como SARIMAX y Holt-Winters mantienen ventajas en términos de interpretabilidad, eficiencia computacional y estabilidad predictiva frente a alternativas más complejas (Wang et al., 2021).

Esta coexistencia de enfoques confirma que no existe un modelo de pronóstico universalmente superior para todas las situaciones, puesto que el desempeño depende de las características específicas de la serie de demanda, tales como tendencia, estacionalidad, aleatoriedad e intermitencia (Douaioui et al., 2024).

A pesar del amplio desarrollo de la literatura, persiste una brecha relevante. La mayoría de los estudios recientes se concentra en entornos con alta disponibilidad de datos y alta complejidad analítica, mientras que muchas empresas manufactureras de bienes de consumo masivo requieren modelos que combinen precisión, interpretabilidad y facilidad de implementación. Adicionalmente, persiste el uso de métodos no sistemáticos basados en juicio experto, lo que evidencia la necesidad de enfoques metodológicos reproducibles y operativamente viables (Aidoo-Anderson et al., 2025).

En este contexto, el objetivo de este estudio fue evaluar y comparar modelos de series de tiempo para el pronóstico de la demanda en un entorno Make-to-Stock, con el fin de optimizar la planificación de la producción.

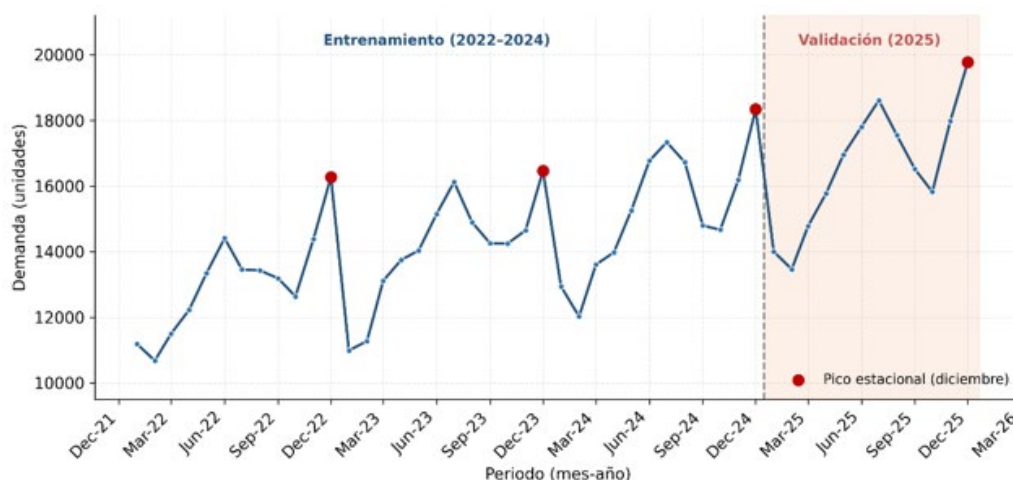
2. Metodología

La investigación adoptó un enfoque cuantitativo aplicado, con diseño no experimental y longitudinal, mediante el análisis de una serie histórica de demanda. Se aplicaron diferentes modelos de pronóstico de series de tiempo; se evaluó comparativamente su precisión predictiva y, a partir del modelo que presentó el mejor desempeño, se generó el pronóstico operativo utilizado como insumo para la planificación de la producción.

El estudio se desarrolló en una empresa industrial de producción en línea bajo estrategia Make-to-Stock, perteneciente al sector de bienes de consumo masivo. Se analizó la demanda mensual durante 48 meses, comprendidos entre enero de 2022 y diciembre de 2025. El análisis exploratorio evidenció una demanda media de 13.958 unidades mensuales, con valores que oscilaron entre 10.682 y 17.742 unidades, y un coeficiente de variación del 12,4%, lo que refleja una variabilidad moderada característica de productos de rotación regular (ver Figura 1).

Figura 1

Comportamiento histórico de la demanda mensual y partición de la serie en entrenamiento y validación (enero 2022 – diciembre 2025)



Nota. Elaboración propia a partir de la base de datos de demanda de la empresa. Los puntos en color rojo señalan los picos estacionales correspondientes al mes de diciembre. La región sombreada delimita el periodo reservado para la validación de los modelos.

Partición de la serie y estrategia de validación

Para evaluar la capacidad predictiva real de los modelos, la serie se dividió en dos subconjuntos: 36 meses de entrenamiento, correspondientes al periodo 2022–2024, y 12 meses de validación, correspondientes a 2025. El primer subconjunto se utilizó para estimar los parámetros de cada modelo, mientras que el segundo permitió contrastar los pronósticos con la demanda observada y calcular las métricas de error sobre datos no utilizados en el ajuste.

Esta proporción 75 %–25 % permitió evaluar un ciclo estacional completo y reducir el efecto de posibles valores atípicos mensuales. Una vez seleccionado el modelo de mejor desempeño, este se reentrenó utilizando los 48 meses disponibles, y posteriormente se proyectó hacia el año 2026. De este modo, la validación correspondiente a 2025 funcionó como conjunto de prueba para la comparación de modelos, mientras que el pronóstico de 2026 constituyó el insumo operativo para la planificación de la producción.

Modelos de pronóstico aplicados

Con base en el comportamiento identificado en la serie, caracterizado por tendencia creciente, estacionalidad anual y fluctuaciones irregulares de menor magnitud, se aplicaron siete métodos de pronóstico de demanda con distintos niveles de complejidad. La selección incluyó modelos clásicos de suavizamiento, como el promedio móvil y el suavizamiento exponencial simple, fundamentados en los aportes de Brown (1959), así como métodos orientados a capturar tendencia y estacionalidad, entre ellos los modelos de Holt y Holt-Winters, sustentados en Holt (2004) y Winters (1960).

De manera complementaria, la comparación entre técnicas básicas, modelos estacionales y descomposición de series temporales se apoyó en enfoques metodológicos contemporáneos sobre pronóstico y planificación de operaciones (Hyndman & Athanasopoulos, 2021; Kumar et al., 2024; Park & Yang, 2024).

Promedio móvil simple

$$F_{t+1} = \frac{1}{n} \sum_{i=0}^{n-1} D_{t-i}$$

Promedio móvil ponderado

$$F_{t+1} = \sum_{i=0}^{n-1} w_i D_{t-i}, \quad \sum_{i=0}^{n-1} w_i = 1$$

Suavizamiento exponencial simple

$$F_{t+1} = \alpha D_t + (1 - \alpha) F_t$$

Método de Holt (suavizamiento exponencial doble)

$$\begin{aligned} L_t &= \alpha D_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ F_{t+m} &= L_t + mT_t \end{aligned}$$

Holt-Winters aditivo

$$\begin{aligned} L_t &= \alpha(D_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma(D_t - L_t) + (1 - \gamma)S_{t-s} \\ F_{t+m} &= L_t + mT_t + S_{t-s+m} \end{aligned}$$

Holt-Winters multiplicativo

$$\begin{aligned} L_t &= \alpha \frac{D_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma \frac{D_t}{L_t} + (1 - \gamma)S_{t-s} \\ F_{t+m} &= (L_t + mT_t)S_{t-s+m} \end{aligned}$$

Descomposición de series de tiempo

$$D_t = T_t \times S_t \times I_t$$

Métricas de evaluación del desempeño

La selección de múltiples métricas responde a la recomendación metodológica de evitar la evaluación de la exactitud predictiva mediante un único indicador, debido a que cada medida captura una dimensión distinta del error, tal como señalan Hyndman y Koehler (2006) y Hyndman y Athanasopoulos (2021). En este sentido, la desviación absoluta media permitió cuantificar la magnitud promedio del error en unidades de demanda, mientras que el error cuadrático medio penalizó con mayor intensidad las desviaciones elevadas.

Por su parte, el error porcentual absoluto medio facilitó la interpretación relativa del error y la comparación del desempeño entre modelos, criterio también utilizado en estudios recientes de pronóstico aplicado, como los de Park y Yang (2024) y Rao et al. (2023). Adicionalmente, se incorporó la señal de rastreo para identificar la presencia de sesgo sistemático, el cual puede generar sobreestimaciones o subestimaciones que afectan la planificación de inventarios, tal como se reconoce en aplicaciones recientes de planificación basadas en pronósticos de demanda (Kumar et al., 2024).

Desviación absoluta media (MAD)

$$MAD = \frac{1}{n} \sum_{t=1}^n |D_t - F_t|$$

Error cuadrático medio (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (D_t - F_t)^2$$

Error porcentual absoluto medio (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{D_t - F_t}{D_t} \right| \times 100$$

Señal de rastreo (TS)

$$TS = \frac{\sum_{t=1}^n (D_t - F_t)}{MAD}$$

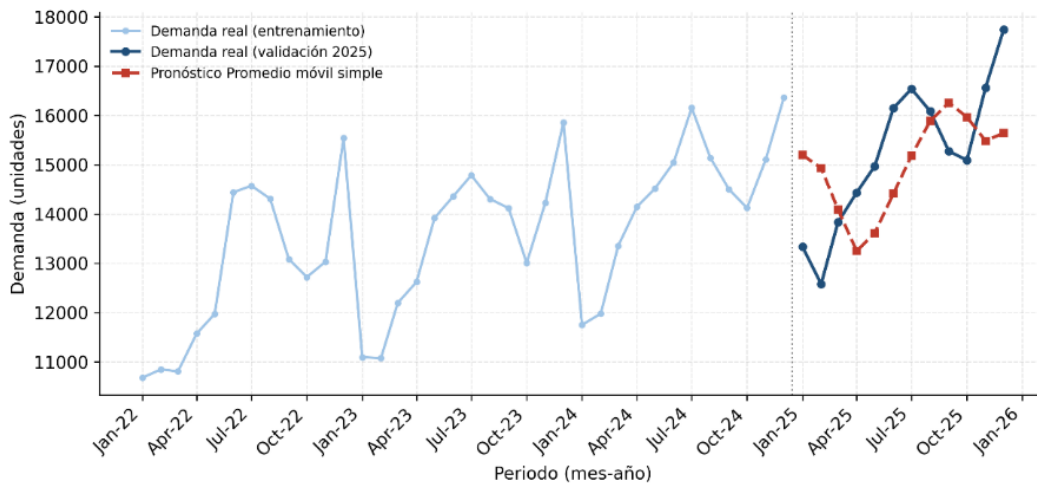
3. Resultados

Promedio móvil simple

La Figura 2 muestra cómo el pronóstico reacciona tarde ante las subidas y bajadas, y no anticipa el pico estacional de fin de año. Su error porcentual fue del 8,54%, con MAD de 1.277,86 unidades y MSE de 2.040.479. La señal de rastreo, de 2,09, se mantiene dentro de control, lo que descarta un sesgo marcado.

Figura 2

Pronóstico mediante promedio móvil simple frente a la demanda real (validación 2025)



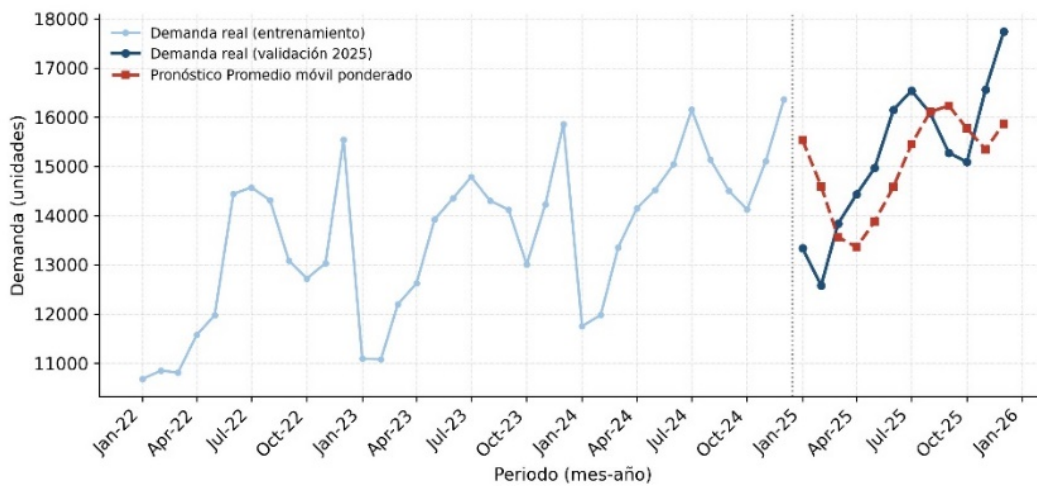
Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Promedio móvil ponderado

La Figura 3 evidencia un pronóstico que se ajusta con mayor rapidez a los cambios de nivel; sin embargo, mantiene el rezago característico de los promedios móviles y no logra capturar el repunte registrado al final del año.

Figura 3

Pronóstico mediante promedio móvil ponderado frente a la demanda real (validación 2025)



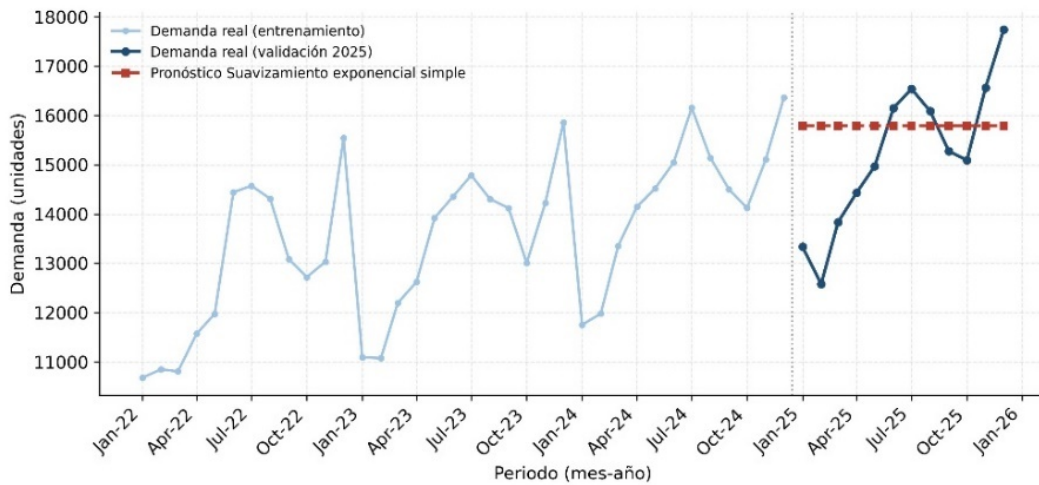
Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Suavizamiento exponencial simple

Este modelo presenta una señal de rastreo de $-5,45$, fuera del rango de control, como se observa en la Figura 4; además, registra un error porcentual absoluto medio (MAPE) de $8,76\%$, lo que confirma su limitada pertinencia para series con tendencia creciente y patrón estacional.

Figura 4

Pronóstico mediante suavizamiento exponencial simple frente a la demanda real (validación 2025)



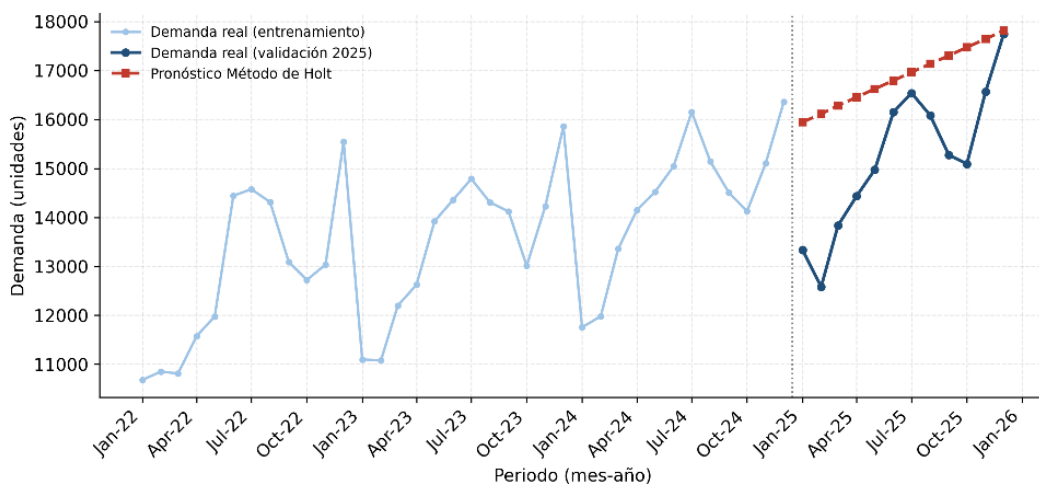
Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Método de Holt

Se capturó la tendencia creciente; sin embargo, al omitir el componente estacional, generó una proyección ascendente que sobreestimó la demanda durante gran parte del año 2025, como se observa en la Figura 5. Este comportamiento produjo la señal de rastreo más extrema del estudio (−12,00), así como los mayores errores entre los modelos exponenciales, con un MAPE de 11,62 %, un MAD de 1.661,45 unidades y un MSE de 3.727.367.

Figura 5

Pronóstico mediante el método de Holt frente a la demanda real (validación 2025)



Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).


Holt-Winters aditivo

Incorporó tanto la tendencia como la estacionalidad, logrando un ajuste cercano a la demanda real observada en 2025, como se evidencia en la Figura 6. Sus indicadores de desempeño fueron considerablemente inferiores a los de los modelos previos, con un MAPE de 2,49 %, un MAD de 374,54

unidades y un MSE de 182.518. Asimismo, la señal de rastreo de 0,16 evidenció un pronóstico prácticamente insesgado.

Figura 6

Pronóstico mediante Holt-Winters aditivo frente a la demanda real (validación 2025)



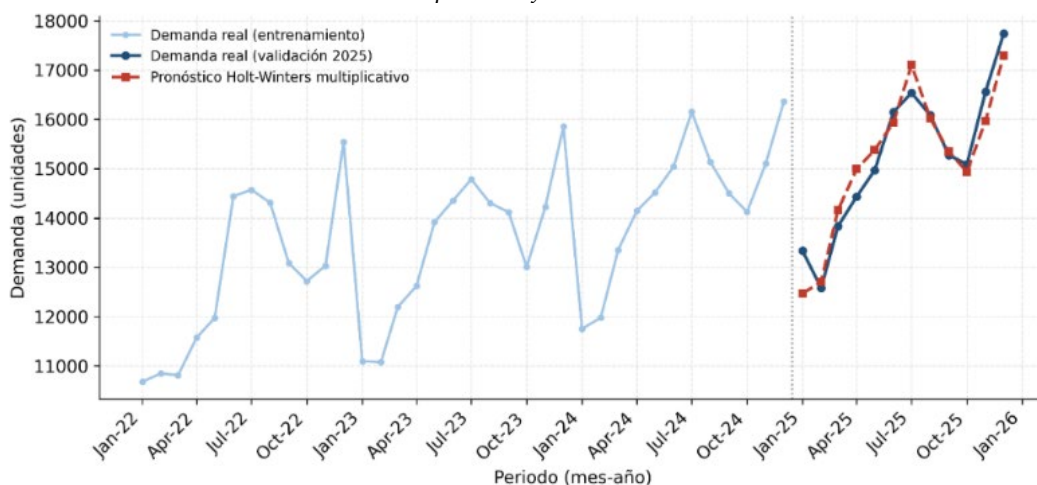
Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Holt-Winters multiplicativo

Al considerar la estacionalidad como proporcional al nivel de la demanda, se obtuvo un ajuste cercano a la serie real correspondiente a 2025, como se observa en la Figura 7. Sus indicadores de desempeño fueron los mejores en términos relativos, con un MAPE de 2,43 %, un MAD de 365,59 unidades y un MSE de 191.731. Asimismo, la señal de rastreo de 0,73 se mantuvo próxima a cero y dentro del rango de control, lo que evidencia un pronóstico preciso y sin sesgo relevante.

Figura 7

Pronóstico mediante Holt-Winters multiplicativo frente a la demanda real (validación 2025)



Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Descomposición de series de tiempo

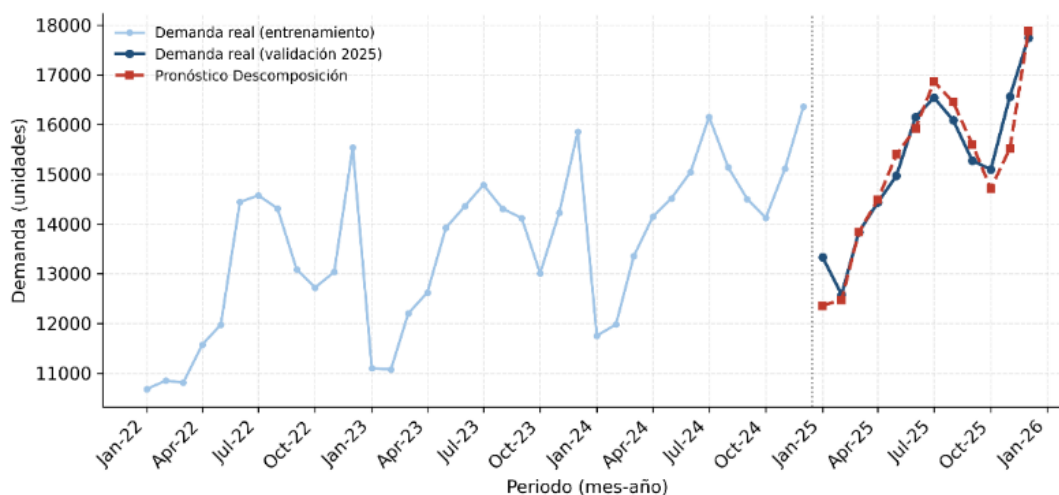
El último modelo descompone la serie en sus componentes de tendencia, estacionalidad e irregularidad para la reconstrucción del pronóstico. La Figura 8 evidencia un ajuste muy cercano a la demanda real observada en 2025, con una adecuada captura tanto del valle inicial como del repunte de diciembre.

En términos de magnitud del error, este modelo presenta los mejores resultados del estudio, con un MAPE de 2,40 %, un MAD de 364,79 unidades y un MSE de 234.572. No obstante, la señal de rastreo se incrementa a 3,05, valor que, si bien se mantiene dentro del rango de control, se aproxima a su límite superior y sugiere una leve tendencia a la subestimación en la segunda mitad del año.

Adicionalmente, el modelo de descomposición ofrece la ventaja de desagregar la contribución de cada componente de la serie, lo que permite una interpretación más detallada del comportamiento de la demanda más allá de la precisión predictiva puntual.

Figura 8

Pronóstico mediante descomposición de series de tiempo frente a la demanda real (validación 2025)



Nota. Elaboración propia a partir de la base de datos de la empresa. La línea punteada separa el entrenamiento (2022–2024) de la validación (2025).

Comparación de modelos y selección

La selección del modelo, sin embargo, no depende exclusivamente de la magnitud del error. Como se observa en la Tabla 1, el modelo de descomposición presenta el menor MAPE; no obstante, su señal de rastreo (3,05) se aproxima al límite superior del rango de control, lo que evidencia una tendencia a la subestimación, especialmente relevante en sistemas Make-to-Stock debido a su asociación con posibles quiebres de inventario.

Por su parte, el modelo aditivo exhibe el pronóstico más insesgado ($TS = 0,16$), aunque con un MAPE ligeramente superior. En contraste, el modelo Holt-Winters multiplicativo logra un equilibrio entre ambos criterios, con un MAPE de 2,43 % —uno de los mejores del estudio— y una señal de rastreo de 0,73, cercana a cero y dentro del rango de control.

De acuerdo con el criterio integral de exactitud y ausencia de sesgo definido en la metodología, se selecciona el modelo Holt-Winters multiplicativo como el más adecuado para la planificación de la producción. Esta elección es consistente con la naturaleza de la serie analizada, caracterizada por una

estacionalidad cuya amplitud crece proporcionalmente con el nivel de la demanda, comportamiento que la formulación multiplicativa reproduce por construcción.

Tabla 1

Comparación del desempeño de los modelos de pronóstico en el periodo de validación (2025)

Modelo	MAD	MSE	MAPE (%)	TS
Descomposición	364.79	234,572	2.40	3.05
Holt-Winters multiplicativo	365.59	191,731	2.43	0.73
Holt-Winters aditivo	374.54	182,518	2.49	0.16
Promedio móvil ponderado	1,171.77	1,778,516	7.86	1.97
Promedio móvil simple	1,277.86	2,040,479	8.54	2.09
Suavizamiento exponencial simple	1,261.13	2,382,219	8.76	-5.45
Método de Holt	1,661.45	3,727,367	11.62	-12.00

Nota. Elaboración propia. MAD y MSE se expresan en unidades y unidades al cuadrado; MAPE en porcentaje. La fila resaltada corresponde al modelo seleccionado. TS = señal de rastreo.

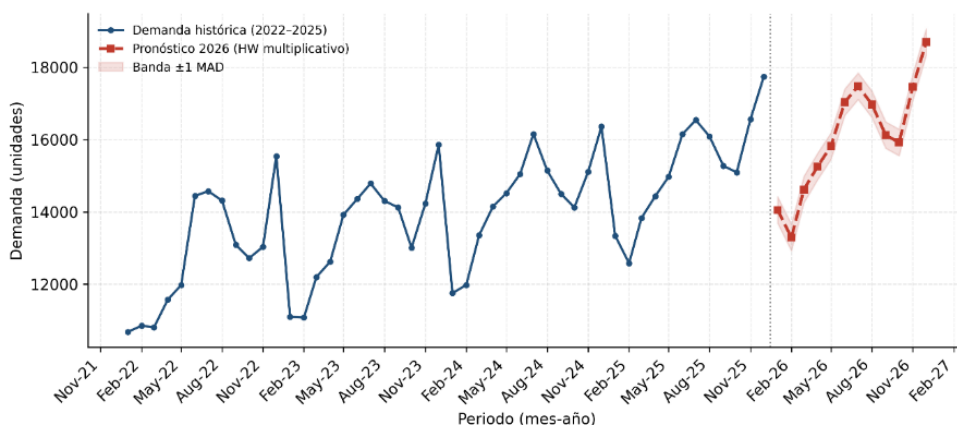
Pronóstico operativo para 2026

Una vez seleccionado el modelo, Holt-Winters multiplicativo se reentrenó utilizando los 48 meses disponibles con el fin de proyectar la demanda correspondiente al año 2026. Como se observa en la Figura 9, el pronóstico reproduce el patrón histórico de la serie, evidenciando un valle en febrero, un crecimiento progresivo hacia mediados de año y un pico en diciembre.

Asimismo, se incorpora una banda de ± 1 MAD como margen esperado de error. Las proyecciones mensuales fluctúan entre 13.291 y 18.697 unidades, con una media estimada de 16.061 unidades y un total anual proyectado de 192.732 unidades.

Figura 9

Pronóstico operativo de la demanda para 2026 mediante Holt-Winters multiplicativo



Nota. Elaboración propia a partir de la base de datos de la empresa. La banda sombreada representa el margen de ± 1 MAD del modelo. La línea punteada separa la demanda histórica del horizonte pronosticado.

4. Discusión

El hallazgo central de este estudio, referido a la superioridad de los modelos que incorporan estacionalidad frente a aquellos que no lo hacen, coincide con la evidencia consolidada en la literatura reciente sobre pronóstico de demanda. La diferencia superior a cinco puntos porcentuales en el MAPE entre Holt-Winters y los promedios móviles confirma que, cuando la serie presenta patrones estacionales definidos, la selección del modelo constituye un factor determinante en la calidad del pronóstico.

Estudios comparativos previos han reportado conclusiones equivalentes al contrastar distintas familias de modelos sobre series reales de consumo y energía, evidenciando la superioridad de aquellos capaces de representar adecuadamente la estructura de tendencia y estacionalidad (Park & Yang, 2024; Rao et al., 2023). En la misma línea, revisiones sistemáticas del área destacan que la adecuación entre las características de la serie y el modelo es más determinante que la sofisticación metodológica en sí misma (Douaioui et al., 2024).

Un aspecto relevante identificado en este estudio es el papel de la señal de rastreo en la selección del modelo final. Aunque la descomposición presentó el menor error de magnitud, su tendencia a la subestimación la hace menos adecuada que Holt-Winters multiplicativo en un entorno Make-to-Stock. Esta distinción resulta crítica, ya que gran parte de la literatura aplicada prioriza métricas de magnitud como el MAPE o el RMSE, relegando frecuentemente el análisis del sesgo (Wang et al., 2021; Aldahmani et al., 2024).

Sin embargo, en contextos de inventario, el sesgo sistemático tiene implicaciones operativas directas, debido a que la subestimación genera quiebres de stock, mientras que la sobreestimación incrementa los costos de almacenamiento. Por ello, el control del sesgo resulta tan relevante como la precisión del pronóstico (Kumar et al., 2024). En este sentido, la utilización conjunta de múltiples indicadores de error se alinea con las recomendaciones metodológicas clásicas de evaluación de pronósticos (Hyndman & Koehler, 2006; Hyndman & Athanasopoulos, 2021).

El estudio también se inserta en el debate contemporáneo sobre la vigencia de los modelos clásicos frente a las técnicas de aprendizaje automático y aprendizaje profundo. La literatura reciente ha explorado arquitecturas avanzadas como redes recurrentes, modelos basados en atención, aprendizaje por refuerzo y redes neuronales sobre grafos, que muestran mejoras significativas en escenarios de alta complejidad y disponibilidad de datos (Lei et al., 2025; Yang et al., 2025; Theodoridis & Tsadiras, 2025; Sifuentes-Domínguez et al., 2026).

No obstante, estas técnicas requieren altos volúmenes de datos, infraestructura computacional avanzada y capacidades técnicas especializadas, lo que limita su aplicabilidad en muchas empresas manufactureras de producción en línea. Asimismo, sacrifican interpretabilidad, un aspecto clave para la toma de decisiones operativas. La evidencia empírica indica que, en numerosos contextos, los modelos estadísticos clásicos mantienen un equilibrio superior entre precisión, costo computacional y transparencia (Park & Yang, 2024; Kontopoulou et al., 2023). Los resultados obtenidos en este estudio respaldan esta conclusión, al demostrar que un modelo de baja complejidad computacional puede alcanzar errores inferiores al 2,5 % sin requerir infraestructura especializada.

Sin embargo, la idoneidad de los modelos clásicos depende de la naturaleza de la demanda. En series con alta intermitencia, como repuestos o productos de baja rotación, los métodos tradicionales de suavizamiento pierden efectividad y requieren enfoques especializados (Fan et al., 2023; Hong et al., 2023). Esta dependencia del patrón de demanda también ha sido evidenciada en la industria automotriz, donde las características del producto condicionan la selección del método de pronóstico

(Fu et al., 2026; Ranabhatt et al., 2025). En contraste, la demanda continua y estacional analizada en este estudio se ubica en el dominio donde los modelos de suavizamiento estacional presentan mejor desempeño, lo que explica los resultados obtenidos.

Los hallazgos obtenidos refuerzan la concepción del pronóstico como el primer eslabón del proceso de planificación de la producción, y no como un fin aislado. La proyección de la demanda para 2026 derivada del modelo seleccionado constituye un insumo fundamental para la planificación del plan maestro de producción, la gestión de materiales y el dimensionamiento de inventarios de seguridad, integración que ha sido identificada como crítica para el desempeño de la cadena de suministro (Harshvardhan et al., 2025; Basavaraju & Fatahi Valilai, 2025; Goel et al., 2024). Esta articulación resulta especialmente relevante en pequeñas y medianas empresas, donde la ausencia de procesos sistemáticos de pronóstico limita la eficiencia operativa y la competitividad (Aidoo-Anderson et al., 2025).

Este estudio presenta ciertas limitaciones que deben ser consideradas. En primer lugar, el análisis se basa en una única serie de demanda agregada, lo que limita la generalización de los resultados a contextos con patrones distintos, como demanda intermitente o no estacional. En segundo lugar, el conjunto de modelos evaluados se restringe a técnicas clásicas de series de tiempo, sin incluir enfoques de aprendizaje automático que podrían aportar mejoras en presencia de variables exógenas. En tercer lugar, el pronóstico se construyó exclusivamente a partir de datos históricos de demanda, sin incorporar factores externos como precios, promociones o condiciones macroeconómicas.

Finalmente, la validación se realizó en un único horizonte temporal, por lo que futuras investigaciones podrían fortalecer la robustez del análisis mediante esquemas de validación cruzada en ventanas múltiples. Estas limitaciones no invalidan los hallazgos, sino que delimitan su alcance y abren nuevas líneas de investigación.

5. Conclusiones

El presente estudio aplicó y evaluó comparativamente siete modelos de series de tiempo y suavizamiento para el pronóstico de la demanda en una empresa de producción en línea bajo estrategia Make-to-Stock, con el propósito de seleccionar el modelo más adecuado para optimizar la planificación de la producción.

Se concluye que la capacidad de los modelos para incorporar la estacionalidad constituye el principal factor explicativo de su desempeño predictivo. En este sentido, los modelos que integran dicho componente, particularmente Holt-Winters y la descomposición de series, redujeron el error porcentual a valores cercanos al 2,4 %, en contraste con los métodos que no la consideran, los cuales superaron el 7,8 %. Esta diferencia evidencia que, en series con patrones estacionales definidos, la adecuación estructural del modelo a la serie de demanda resulta determinante frente a otros criterios de selección.

Asimismo, se confirma que la evaluación del desempeño no debe basarse exclusivamente en métricas de magnitud del error, ya que indicadores como la señal de rastreo permiten identificar sesgos sistemáticos relevantes. En este caso, aunque el modelo de descomposición presentó el menor error, evidenció una tendencia a la subestimación, mientras que Holt-Winters multiplicativo combinó alta precisión con ausencia de sesgo, consolidándose como el modelo más adecuado para el entorno Make-to-Stock.

El pronóstico generado para el año 2026, con una demanda media de 16.061 unidades mensuales y un total anual aproximado de 192.700 unidades, proporciona un insumo cuantitativo para la planificación del plan maestro de producción, la gestión de materiales y el dimensionamiento de inventarios de seguridad, reforzando el papel del pronóstico como base operativa de la planificación productiva.

Finalmente, se observó que los modelos clásicos de series de tiempo, debido a su bajo costo computacional e interpretabilidad, resultan suficientes para sustentar decisiones de producción en contextos de demanda continua y estacional. No obstante, se recomienda ampliar el análisis hacia escenarios multivariados, la incorporación de variables exógenas y el uso de técnicas de aprendizaje automático para contextos de mayor complejidad.

Referencias

- Aidoo-Anderson, A., Polychronakis, Y., Sapountzis, S., & Kelly, S. (2025). Investigating demand forecasting practices and challenges in Ghana's Manufacturing Pharmaceutical (MPharma) small and medium enterprises (SMEs): Insights and recommendations. *International Journal of Production Research*, 63(21), 7899–7920. <https://doi.org/10.1080/00207543.2025.2508335>
- Aldahmani, E., Alzubi, A., & Iyiola, K. (2024). Demand forecasting in supply chain using uni-regression deep approximate forecasting model. *Applied Sciences*, 14(18), 8110. <https://doi.org/10.3390/app14188110>
- Basavaraju, K., & Fatahi Valilai, O. (2025). Developing a demand planning strategy for joint forecasting and employing analytical tool in an empirical case study. *Discover Applied Sciences*, 7(345). <https://doi.org/10.1007/s42452-025-06740-9>
- Brown, R. G. (1959). *Statistical forecasting for inventory control*. McGraw-Hill. <https://catalog.hathitrust.org/Record/001125212>
- Douaioui, K., Oucheikh, R., Benmoussa, O., & Mabrouki, C. (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. *Applied System Innovation*, 7(5), 93. <https://doi.org/10.3390/asi7050093>
- Fan, L., Liu, X., Mao, W., Yang, K., & Song, Z. (2023). Spare Parts Demand Forecasting Method Based on Intermittent Feature Adaptation. *Entropy*, 25(5), 764. <https://doi.org/10.3390/e25050764>
- Fu, W., Bian, H., Chen, J., & Jing, S. (2026). Tree-based machine learning intermittent demand forecasting for spare parts in electric vehicle manufacturing. *World Electric Vehicle Journal*, 17(3), 127. <https://doi.org/10.3390/wevj17030127>
- Goel, L., Nandal, N., Gupta, S., Karanam, M., Yeluri, L., Pandey, A., Rozhdestvenskiy, O., & Grabovy, P. (2024). Revealing the dynamics of demand forecasting in supply chain management: A holistic investigation. *Cogent Engineering*, 11(1), 2368104. <https://doi.org/10.1080/23311916.2024.2368104>
- Harshvardhan, M., Curtland, C., Hwang, J., VanDam, C., Ghozeil, A., Neto, P., Marie, F., & Liu, C. (2025). Print demand forecasting with machine learning at HP Inc. *INFORMS Journal on Applied Analytics*, 55(6), 469–483. <https://doi.org/10.1287/inte.2024.0126>
- Holt, C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20(1), 5–10. <https://doi.org/10.1016/j.ijforecast.2003.09.015>
- Hong, K., Ren, Y., Li, F., Mao, W., & Gao, X. (2023). Robust interval prediction of intermittent demand for spare parts based on tensor optimization. *Sensors*, 23(16), 7182. <https://doi.org/10.3390/s23167182>
- Hyndman, R., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3.^a ed.). OTexts. <https://otexts.com/fpp3/>

- Hyndman, R., & Koehler, A. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Kontopoulou, V., Panagopoulos, A., Kakkos, I., & Matsopoulos, G. (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet*, 15(8), 255. <https://doi.org/10.3390/fi15080255>
- Kumar, L., Khedlekar, S., & Khedlekar, U. (2024). A comparative assessment of holt winter exponential smoothing and autoregressive integrated moving average for inventory optimization in supply chains. *Supply Chain Analytics*, 8, 100084. <https://doi.org/10.1016/j.sca.2024.100084>
- Lei, C., Zhang, H., Wang, Z., & Miao, Q. (2025). Deep Learning for Demand Forecasting: A Framework Incorporating Variational Mode Decomposition and Attention Mechanism. *Processes*, 13(2), 594. <https://doi.org/10.3390/pr13020594>
- Park, M.-J., & Yang, H.-S. (2024). Comparative Study of Time Series Analysis Algorithms Suitable for Short-Term Forecasting in Implementing Demand Response Based on AMI. *Sensors*, 24(22), 7205. <https://doi.org/10.3390/s24227205>
- Ranabhatt, N., Barreto, S., Pimpão, M., & Prates, P. (2025). Demand Forecasting in the Automotive Industry: A Systematic Literature Review. *Forecasting*, 7(4), 73. <https://doi.org/10.3390/forecast7040073>
- Rao, C., Zhang, Y., Wen, J., Xiao, X., & Goh, M. (2023). Energy demand forecasting in China: A support vector regression-compositional data second exponential smoothing model. *Energy*, 263, 125955. <https://doi.org/10.1016/j.energy.2022.125955>
- Sifuentes-Domínguez, S., Mejía-Muñoz, J.-M., Cruz-Mejía, O., Pizarro-Gurrola, R., Domínguez-Flores, A.-S., & Ortega-Máynez, L. (2026). Predicting Demand in Supply Chain Management: A Decision Support System Using Graph Convolutional Networks. *Future Internet*, 18(1), 26. <https://doi.org/10.3390/fi18010026>
- Theodoridis, G., & Tsadiras, A. (2025). Retail Demand Forecasting: A Comparative Analysis of Deep Neural Networks and the Proposal of LSTMixer, a Linear Model Extension. *Information*, 16(7), 596. <https://doi.org/10.3390/info16070596>
- Wang, C.-C., Chien, C.-H., & Trappey, A. (2021). On the Application of ARIMA and LSTM to Predict Order Demand Based on Short Lead Time and On-Time Delivery Requirements. *Processes*, 9(7), 1157. <https://doi.org/10.3390/pr9071157>
- Winters, P. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. *Management Science*, 6(3), 324–342. <https://doi.org/10.1287/mnsc.6.3.324>
- Yang, Y., Wang, M., Wang, J., Li, P., & Zhou, M. (2025). Multi-Agent Deep Reinforcement Learning for Integrated Demand Forecasting and Inventory Optimization in Sensor-Enabled Retail Supply Chains. *Sensors*, 25(8), 2428. <https://doi.org/10.3390/s25082428>

Transparencia

Conflicto de interés

Los autores declaran que no existen conflictos de interés de naturaleza alguna como parte de la presente investigación.

Fuente de financiamiento

Los autores financiaron completamente la investigación.

Contribución de autoría

Johanna Graciela Briones Franco: Conceptualización, metodología, validación, análisis formal, investigación, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, recursos, supervisión.

Byron Daniel Erazo Rodríguez: Conceptualización, metodología, validación, análisis formal, investigación, gestión de datos, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos, supervisión.

Edison Hernán Morales Machado: Conceptualización, software, validación, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, supervisión.

Marco Antonio Santillán Tasigchana: Conceptualización, validación, análisis formal, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos.

Los autores contribuyeron activamente en el análisis de los resultados, revisión y aprobación del manuscrito final.