

Ciencia Latina Revista Científica Multidisciplinaria, Ciudad de México, México.

ISSN 2707-2207 / ISSN 2707-2215 (en línea), marzo-abril 2025,

Volumen 9, Número 2.

https://doi.org/10.37811/cl_rcm.v9i2

OPTIMIZACIÓN DEL PROCESO DE ALMACENAJE EN UNA EMPRESA FARMACÉUTICA

OPTIMIZING THE STORAGE PROCESS IN A
PHARMACEUTICAL COMPANY

Israel Becerril Rosales

Tecnológico Nacional de México, México

Jaqueline Briseydi Andere Cruz

Tecnológico Nacional de México, México

DOI: https://doi.org/10.37811/cl_rcm.v9i2.17439

Optimización del Proceso de Almacenaje en una Empresa Farmacéutica

Israel Becerril Rosales¹

israel.becerril@tesjo.edu.mx

<https://orcid.org/0000-0001-6985-1354>

Tecnológico Nacional de México

México/Tecnológico de Estudios Superiores
de Jocotitlán

Jaqueleine Briseydi Andere Cruz

2020150480036@tesjo.edu.mx

<https://orcid.org/0009-0002-7942-6110>

Tecnológico Nacional de México

México/Tecnológico de Estudios Superiores
de Jocotitlán

RESUMEN

En el ámbito de los inventarios, los pronósticos son fundamentales para gestionar eficientemente los recursos, evitar excesos o faltantes de stock, y optimizar costos operativos. Los pronósticos son esenciales para la gestión eficiente de inventarios, ya que permiten anticipar la demanda y tomar decisiones estratégicas. El presente artículo analiza las ventas de 15 artículos farmacéuticos a lo largo de un período de doce meses con el objetivo de generar pronósticos precisos y ajustados a la tendencia de cada producto. Para ello, se emplearon tres métodos de pronóstico: Stepwise, Box & Jenkins y Holt-Winters. El procesamiento y análisis de datos se realizaron utilizando Microsoft Excel, aprovechando sus herramientas estadísticas y de modelado para la implementación de los métodos de pronóstico. La precisión de los pronósticos se midió a través del Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE), permitiendo comparar el desempeño de cada método, de esta forma, se identificó el método más eficiente en la mayoría de los casos es Holt-Winters. Los resultados destacan la importancia de seleccionar el modelo de pronóstico adecuado en función de las características de los datos históricos, permitiendo mejorar la precisión de las predicciones y la planificación estratégica en el sector farmacéutico.

Palabras clave: optimización, pronóstico, Step wise, Holt Winters, Box&Jenkins

¹ Autor principal

Correspondencia: israel.becerril@tesjo.edu.mx

Optimizing the Storage Process in a Pharmaceutical Company

ABSTRACT

In the field of inventories, forecasts are essential to efficiently manage resources, avoid excess or shortages of stock, and optimize operating costs. Forecasts are essential for efficient inventory management, as they allow you to anticipate demand and make strategic decisions. This article analyzes the sales of 15 pharmaceutical items over a period of twelve months with the aim of generating accurate forecasts adjusted to the trend of each product. For this, three forecasting methods were used: Stepwise, Box & Jenkins and Holt-Winters. Data processing and analysis were carried out using Microsoft Excel, taking advantage of its statistical and modeling tools for the implementation of forecasting methods. The precision of the forecasts was measured through the Mean Absolute Error (MAE) and the Mean Square Error (MSE), allowing the performance of each method to be compared, in this way, the most efficient method was identified in most cases, Holt-Winters. The results highlight the importance of selecting the appropriate forecasting model based on the characteristics of the historical data, allowing to improve the accuracy of predictions and strategic planning in the pharmaceutical sector.

Keywords: optimization, forecasting, Step wise, Holt Winters, Box&Jenkins

Artículo recibido 13 marzo 2025

Aceptado para publicación: 19 abril 2025



INTRODUCCIÓN

La optimización del proceso de almacenaje es fundamental para garantizar la eficiencia operativa y la competitividad de las empresas farmacéuticas. En un sector tan exigente como el farmacéutico, donde los márgenes de error pueden tener consecuencias críticas, contar con un sistema de gestión de inventarios preciso y eficiente no solo es una necesidad, sino una obligación. Uno de los métodos más efectivos para lograr esta optimización es el uso de pronósticos, que permiten prever la demanda de productos con una alta precisión, minimizando el riesgo de desabastecimiento o exceso de inventario.

El pronóstico de demanda, basado en el análisis de datos históricos y patrones de consumo, proporciona a las empresas una herramienta poderosa para anticipar las necesidades de almacenamiento de manera más efectiva. A través de modelos estadísticos y técnicas de análisis predictivo, las compañías farmacéuticas pueden gestionar de forma más precisa sus inventarios, reduciendo costos asociados al almacenamiento innecesario o a la falta de productos críticos, como medicamentos esenciales.

La implementación de sistemas de pronósticos en el proceso de almacenaje no solo mejora la eficiencia logística, sino que también contribuye al cumplimiento normativo, garantizando que los productos sean almacenados bajo condiciones adecuadas y en los tiempos estipulados, preservando su calidad y seguridad. Además, la optimización de los inventarios permite mejorar el flujo de efectivo y garantizar la disponibilidad continua de productos, lo cual es crucial en un entorno tan dinámico y sensible como el sector farmacéutico.

Pronóstico

El pronóstico es una estimación o predicción sobre un evento futuro, basada en análisis de datos, tendencias y patrones. Los pronósticos son una herramienta útil para el establecimiento de los objetivos en toda planeación, los cuales no influyen en el porvenir sino proporcionan un aproximado conocimiento de este, lo cual no sucede en el plan que basado en el pronóstico sí determina el futuro (Ch.). El pronóstico de la demanda es el proceso de predecir o estimar qué productos y en qué cantidades serán requeridos por los consumidores en un determinado periodo de tiempo. Por lo tanto, consiste en desarrollar proyecciones futuras de ventas, para así estar preparados para abastecer las necesidades del mercado. Conocer el pronóstico es útil para adaptar nuestras operaciones con el objetivo de contar con



el inventario adecuado, y de esta manera, los picos y valles de la demanda no nos tomen por sorpresa (netlogistik, 2024).

Métodos de pronóstico tradicionales

Los métodos de pronóstico tradicionales se dividen principalmente en dos categorías: cuantitativos y cualitativos.

Métodos Cuantitativos

- **Promedios Móviles:** Se calculan promedios de un conjunto de datos en intervalos de tiempo, lo que ayuda a suavizar las fluctuaciones y detectar tendencias.
- **Suavizado Exponencial:** Asigna pesos decrecientes a los datos pasados, dando más importancia a los datos más recientes.
- **Regresión Lineal:** Analiza la relación entre una variable dependiente y una o más variables independientes para predecir valores futuros.
- **Modelos de Series Temporales:** Se enfocan en patrones y tendencias en datos históricos a lo largo del tiempo.
- **Análisis de Varianza:** Utiliza variaciones en los datos para predecir resultados futuros.

Métodos Cualitativos

- **Juicio de Expertos:** Reúne opiniones de expertos en el tema para hacer estimaciones basadas en su experiencia.
- **Método Delphi:** Un proceso estructurado donde se consulta a un grupo de expertos en varias rondas, refinando las respuestas en cada iteración (Chatfield, 2000).
- **Encuestas:** Recopilan opiniones o predicciones de un grupo específico para pronosticar tendencias.

Estos métodos pueden ser utilizados de forma independiente o combinados, dependiendo del contexto y la disponibilidad de datos.



Método Stepwise

El método Stepwise, o "método de selección paso a paso", es una técnica utilizada en análisis estadístico, especialmente en la regresión, para seleccionar un subconjunto de variables que mejor explican la variabilidad de una variable dependiente (Corte, 2016).

Stepwise regression se puede lograr probando una variable independiente a la vez e ir incluyéndola en el modelo de regresión si es estadísticamente significativa o incluyendo todas las variables independientes potenciales en el modelo y eliminando aquellas que no son estadísticamente significativas. Algunos usan una combinación de ambos métodos, por lo tanto, existen tres enfoques para la regresión por pasos:

- Forward selection comienza sin variables en el modelo, prueba cada variable a medida que se agrega al modelo, luego mantiene las que se consideran estadísticamente más significativas, repitiendo el proceso hasta que los resultados sean óptimos.
- Backward elimination comienza con un conjunto de variables independientes, eliminando una a la vez, luego probando para ver si la variable eliminada es estadísticamente significativa.
- Bidirectional elimination es una combinación de los dos primeros métodos que prueba qué variables deben incluirse o excluirse (Gonzalez, 2019).

Criterios comunes para tomar decisiones durante el proceso stepwise:

- Valor p: Para determinar la importancia de las variables. Solo las variables con un valor p inferior a un umbral (generalmente 0.05) se mantienen.
- Criterios de información: Como el AIC (Criterio de Información de Akaike) o el BIC (Criterio de Información Bayesiano), que penalizan la inclusión de variables no significativas.
- R² ajustado o el error cuadrático medio (RMSE), que ayudan a evaluar el rendimiento del modelo.

Método Holt-Winters

El método de triple suavizado exponencial, también conocido como método de Holt-Winters, es una técnica utilizada en análisis de series de tiempo para predecir valores futuros en función de los patrones históricos de la serie de tiempo. Este método se basa en tres tipos de suavizado exponencial: el suavizado



exponencial simple, el suavizado exponencial doble y el suavizado exponencial triple (Caballero, 2023).

Este método es especialmente útil cuando se espera que el comportamiento de la serie temporal varíe de manera regular a lo largo del tiempo.

Este método se basa en tres componentes principales:

- Nivel (L_t): El valor "promedio" en el tiempo t .
- Tendencia (T_t): El cambio a largo plazo en la serie temporal.
- Estacionalidad (S_t): Los patrones cíclicos o estacionales que se repiten en la serie.

El suavizado exponencial simple se utiliza para suavizar la serie de tiempo y eliminar las fluctuaciones aleatorias. El suavizado exponencial doble se utiliza para modelar tendencias y estacionalidad. El suavizado exponencial triple se utiliza para modelar tendencias, estacionalidad y fluctuaciones aleatorias (fastercapital, s.f.).

El método Holt-Winters tiene dos variantes principales dependiendo de si la estacionalidad es aditiva o multiplicativa. La elección entre estos modelos depende del comportamiento de los datos (biblus).

Modelo aditivo de Holt-Winters

Este modelo se utiliza cuando la magnitud de la estacionalidad es constante, es decir, la estacionalidad no depende del nivel de la serie.

Fórmulas del modelo aditivo:

$$\text{Nivel: } L_t = \alpha(Y_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

Donde:

L_t : Nivel en el tiempo t ,

Y_t : Valor observado en el tiempo t ,

S_{t-m} : Estacionalidad del período $t - m$,

L_{t-1} : Nivel en el período anterior,

T_{t-1} : Tendencia en el período anterior,

α : Coeficiente de suavizamiento para el nivel ($0 \leq \alpha \leq 1$).

$$\text{Tendencia: } T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

Donde:



T_t : Tendencia en el tiempo t ,

L_t : Nivel en el tiempo t ,

L_{t-1} : Nivel en el tiempo $t - 1$,

β : Coeficiente de suavizamiento para la tendencia ($0 \leq \beta \leq 1$).

Estacionalidad: $S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-m}$

Donde:

S_t : Estacionalidad en el tiempo t ,

Y_t : Valor observado en el tiempo t ,

L_t : Nivel en el tiempo t ,

S_{t-m} : Estacionalidad en el período correspondiente $t - m$,

γ : Coeficiente de suavizamiento para la estacionalidad ($0 \leq \gamma \leq 1$).

Pronóstico: $\hat{Y}_{t+h} = L_t + hT_t + S_{t+h-m}$

Donde:

\hat{Y}_{t+h} : Pronóstico para el período $t + h$,

L_t : Nivel estimado en el período t ,

T_t : Tendencia estimada en el período t ,

S_{t+h-m} : Estacionalidad del período $t + h - m$.

Modelo Multiplicativo de Holt-Winters

Este modelo se utiliza cuando la magnitud de la estacionalidad depende del nivel de la serie temporal. Es decir, si el nivel de la serie aumenta, también aumentan los efectos estacionales.

Fórmulas del modelo multiplicativo:

Nivel: $L_t = \alpha(\frac{Y_t}{S_{t-m}}) + (1 - \alpha)(L_{t-1} + T_{t-1})$

Donde:

L_t : Nivel en el tiempo t ,

Y_t : Valor observado en el tiempo t ,

S_{t-m} : Estacionalidad del período $t - m$,

L_{t-1} : Nivel en el período anterior,



T_{t-1} : Tendencia en el período anterior,

α : Coeficiente de suavizamiento para el nivel.

$$\text{Tendencia: } T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

Donde:

T_t : Tendencia en el tiempo t ,

L_t : Nivel en el tiempo t ,

L_{t-1} : Nivel en el tiempo $t - 1$,

β : Coeficiente de suavizamiento para la tendencia.

$$\text{Estacionalidad: } S_t = \gamma\left(\frac{Y_t}{L_t}\right) + (1 - \gamma)S_{t-m}$$

Donde:

S_t : Estacionalidad en el tiempo t ,

Y_t : Valor observado en el tiempo t ,

L_t : Nivel en el tiempo t ,

S_{t-m} : Estacionalidad en el período correspondiente $t - m$,

γ : Coeficiente de suavizamiento para la estacionalidad.

$$\text{Pronóstico: } \hat{Y}_{t+h} = (L_t + hT_t) * S_{t+h-m}$$

Donde:

\hat{Y}_{t+h} : Pronóstico para el período $t + h$,

L_t : Nivel estimado en el período t ,

T_t : Tendencia estimada en el período t ,

S_{t+h-m} : Estacionalidad del período $t + h - m$.

Las series de tiempo se utilizan para analizar el comportamiento de una variable en el tiempo y pueden ser utilizadas para hacer predicciones o proyecciones de valores futuros (Parra, 2023).

Método Box & Jenkins

El método Box-Jenkins es un enfoque sistemático para la modelización y pronóstico de series temporales (Chinlli, 2021). Desarrollado por George Box y Gwilym Jenkins en su libro "Time Series Analysis: Forecasting and Control" (1970), este método se centra en identificar y estimar modelos de series



temporales que sean adecuados para pronosticar comportamientos futuros, especialmente en series que presentan tendencias y estacionalidades.

El objetivo principal del método Box-Jenkins es identificar un modelo adecuado que describa el comportamiento de una serie temporal y ajustar ese modelo para hacer predicciones futuras. El proceso se basa en la identificación, estimación y diagnóstico de modelos estadísticos que representan los datos de series temporales (Chinlli, 2021).

Box y Jenkins han desarrollado modelos estadísticos para series temporales que tienen en cuenta la dependencia existente entre los datos, esto es, cada observación en un momento dado es modelada en función de los valores anteriores (Mauricio, 2007). Los análisis se basan en un modelo explícito. Los modelos se conocen con el nombre genérico de ARIMA (AutoRegressive Integrated Moving Average), que deriva de sus tres componentes AR (Autoregresivo), I(Integrado) y MA (Medias Móviles) (Sabando-García, 2022).

El modelo ARIMA permite describir un valor como una función lineal de datos anteriores y errores debidos al azar, además, puede incluir un componente cíclico o estacional (Rob J Hyndman, 2018). Es decir, debe contener todos los elementos necesarios para describir el fenómeno. Box y Jenkins recomiendan como mínimo 50 observaciones en la serie temporal.

El modelo ARIMA se denota como $ARIMA(p, d, q)$, donde:

p : El número de términos autorregresivos (AR) en el modelo.

d : El número de diferencias necesarias para hacer que la serie sea estacionaria.

q : El número de términos de media móvil (MA) en el modelo (Douglas C. Montgomery, 2015).

La metodología de Box y Jenkins se resume en cuatro fases: La primera fase consiste en identificar el posible modelo ARIMA que sigue la serie, lo que requiere; decidir qué transformaciones aplicar para convertir la serie observada en una serie estacionaria, determinar un modelo ARMA para la serie estacionaria, es decir, los órdenes p y q de su estructura autorregresiva y de media móvil. La segunda fase; seleccionado provisionalmente un modelo para la serie estacionaria, se pasa a la segunda etapa de estimación, donde los parámetros AR y MA del modelo se estiman por máxima verosimilitud y se obtienen sus errores estándar y los residuos del modelo. La tercera fase es el diagnóstico, donde se comprueba que los residuos no tienen estructura de dependencia y siguen un proceso de ruido blanco;



si los residuos muestran estructura se modifica el modelo para incorporarla y se repiten las etapas anteriores hasta obtener un modelo adecuado. La cuarta fase es la predicción, una vez que se ha obtenido un modelo adecuado se realizan predicciones con el mismo (Fernández).

El modelo ARIMA combina tres componentes básicos:

AR (Autorregresivo): El componente autorregresivo (AR) representa la relación de una observación con observaciones anteriores. En un modelo AR, el valor de la serie en el tiempo t depende de sus valores pasados. La forma general de un modelo AR de orden p es: $Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t$

Donde:

$\phi_1, \phi_2, \dots, \phi_p$ son coeficientes autorregresivos,

ϵ_t es el error aleatorio o ruido blanco.

I (Integrado o Diferenciación): La parte integrada (I) se utiliza para hacer que la serie temporal sea estacionaria. Esto significa que la serie no tiene una tendencia a largo plazo y sus propiedades estadísticas no cambian con el tiempo.

La diferenciación se realiza restando el valor anterior de la serie: $\Delta Y_t = Y_t - Y_{t-1}$

Si la serie sigue una tendencia, generalmente se aplica una diferenciación de primer orden para hacer que la serie sea estacionaria. Si la serie es estacional, se puede aplicar una diferenciación estacional.

MA (Media Móvil): El componente de media móvil (MA) modela el valor de la serie temporal como una combinación lineal de los errores pasados. La forma general de un modelo MA de orden q es: $Y_t = \mu + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t$

Donde:

μ es la media de la serie temporal,

$\theta_1, \theta_2, \dots, \theta_q$ son los coeficientes de media móvil,

ϵ_t es el error aleatorio.



El modelo ARIMA (p , d , q) combina estos tres componentes, con p términos autorregresivos, d diferencias para hacer la serie estacionaria, y q términos de media móvil. Este enfoque es ampliamente utilizado en diversas áreas, como la predicción de demanda, precios de activos financieros, producción industrial, y otros campos que involucran análisis de series temporales (Ling Romero & Aylas Bendezú, 2023).

Precisión de pronóstico

La precisión del pronóstico es una medida de qué tan cerca está una predicción o una estimación del resultado real. Se utiliza ampliamente para evaluar el desempeño de modelos y técnicas de pronóstico en diversos campos, como finanzas, meteorología y gestión de la cadena de suministro (FasterCapital, 2024).

La precisión de los pronósticos se puede calcular utilizando varias métricas, según las necesidades específicas y la naturaleza de los pronósticos. Algunas métricas comunes incluyen el error medio absoluto (MAE), el error porcentual absoluto medio (MAPE), el error cuadrático medio (MSE), el error cuadrático medio (RMSE) y el error de pronóstico medio (MFE) (Comm, 2024).

Error Medio Absoluto (MAE - Mean Absolute Error)

El MAE es el promedio de los errores absolutos entre los valores predichos y los reales. Es una de las métricas más simples para medir la precisión del pronóstico. Un valor más bajo de MAE indica una mayor precisión en las predicciones del modelo. A diferencia del RMSE, el MAE no penaliza los errores grandes, lo que significa que otorga igual importancia a todas las predicciones, independientemente de su magnitud (Caballero, LinkedIn, 2023).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

Donde:

Y_i es el valor real (observado),

\hat{Y}_i es el valor predicho,

n es el número de observaciones.



Error Porcentual Absoluto Medio (MAPE - Mean Absolute Percentage Error)

El Porcentaje de Error Absoluto Medio es una métrica comúnmente utilizada en el análisis de series de tiempo y en el campo de la estadística para evaluar la precisión de las predicciones en comparación con los valores reales. A diferencia del MAE (Error Absoluto Medio) y del RMSE (Error Cuadrático Medio), el MAPE se expresa como un porcentaje, lo que facilita la interpretación de la precisión de las predicciones en términos relativos. Un valor más bajo de MAPE indica una mayor precisión en las predicciones del modelo (Caballero, LinkedIn, 2023).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100$$

Donde:

Y_i es el valor real,

\hat{Y}_i es el valor predicho,

n es el número de observaciones.

Error Cuadrático Medio (MSE - Mean Squared Error)

El MSE mide el promedio de los cuadrados de los errores, lo que significa que penaliza más los errores grandes. Es similar al RMSE, pero sin tomar la raíz cuadrada, lo que lo hace más sensible a los errores grandes (Madrigal, 2022).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Donde:

Y_i es el valor real,

\hat{Y}_i es el valor predicho,

n es el número de observaciones.

Error Cuadrático Medio de la Raíz (RMSE - Root Mean Squared Error)

El Error Cuadrático Medio es una métrica de evaluación comúnmente utilizada en el análisis de series de tiempo y en el campo de la estadística para medir la precisión de las predicciones en comparación con los valores reales. El RMSE calcula la raíz cuadrada del promedio de los errores al cuadrado entre



las predicciones del modelo y los valores observados de la serie de tiempo. El RMSE es una métrica de error, por lo que un valor más bajo indica una mayor precisión en las predicciones del modelo. Un RMSE igual a cero implicaría que las predicciones son perfectas y coinciden exactamente con los valores reales (Caballero, LinkedIn, 2023).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$$

Donde:

Y_i es el valor real,

\hat{Y}_i es el valor predicho,

n es el número de observaciones.

Error de Pronóstico Medio (MFE - Mean Forecast Error)

El MFE es el promedio de los errores de pronóstico (residuos), y se calcula como la diferencia promedio entre los valores reales y los valores predichos. A diferencia de las otras métricas, el MFE puede mostrar un sesgo en el modelo, es decir, si el modelo tiende a sobreestimar o subestimar sistemáticamente los valores. Ayuda a detectar el sesgo en las predicciones. Un valor cercano a cero indica que no hay sesgo sistemático en el modelo (Comm, 2024).

$$MFE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)$$

Donde:

Y_i es el valor real,

\hat{Y}_i es el valor predicho,

n es el número de observaciones.

El propósito de este artículo es comparar los métodos de pronóstico de 15 artículos farmacéuticos utilizando el MAE (Error Absoluto Medio) para evaluar la precisión de los métodos Stepwise, Holt Winters y Box & Jenkins, midiendo el error promedio entre los valores reales y los valores pronosticados en términos absolutos, lo que permite identificar el método de pronóstico que genera errores promedio



más bajos de forma consistente y comprensible, ayudando a seleccionar el modelo más adecuado para las necesidades prácticas del análisis.

METODOLOGÍA

Elaborar métodos de pronóstico implica una metodología estructurada que combina análisis de datos históricos, selección de modelos apropiados y validación de resultados. A continuación, se presenta la metodología utilizada para desarrollar nuestros métodos de pronóstico:

- **Definir el objetivo del pronóstico:** Se determina que se quiere predecir, en este caso fue la demanda del consumo de los 15 artículos farmacéuticos considerando un año, de junio a mayo.
- **Recolectar y preparar los datos:** Se recolectaron datos históricos relevantes de 12 meses anteriores de consumo, para ello se aplicó la clasificación ABC tomando como criterio el consumo mensual, y estos son los artículos de la clasificación A.
- **Seleccionar el método de pronóstico:** Se seleccionaron métodos cuantitativos que requieren datos históricos, utilizando métodos básicos y avanzados (Stepwise, Holt Winters, Box & Jenkins).
- **Construir el modelo de pronóstico:** Se realizó el cálculo de los tres métodos de pronósticos apoyados de Microsoft Excel (ver Tabla 1 y 2).



Tabla 1. Pronósticos de cada método de Junio a Noviembre

NO.	MÉTODO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE
1	Demanda real	1,618,475.00	722,033.00	607,859.00	1,690,782.00	1,822,742.00	2,244,278.00
	Stepwise	1,275,151.00	1,267,670.50	1,260,190.00	1,252,709.50	1,245,229.00	1,237,748.50
	Holt Winters	1,590,895.43	636,833.46	553,302.81	1,598,948.78	1,719,183.63	2,089,703.18
	Box & Jenkins		1,292,629.84	576,667.78	485,480.34	1,350,379.33	1,455,771.93
2	Demanda real	106,595.00	317,902.00	210,233.00	84,637.00	134,562.00	212,400.00
	Stepwise	176,530.96	172,293.79	168,056.61	163,819.44	159,582.26	155,345.09
	Holt Winters	94,310.42	270,823.68	189,202.99	198,794.28	125,134.30	226,524.53
	Box & Jenkins		174,398.29	87,128.42	131,595.76	183,466.96	162,847.91
3	Demanda real	6,313.10	12,139.52	14,585.91	21,588.05	24,463.63	12,646.37
	Stepwise	12,945.57	13,137.51	13,329.46	13,521.40	13,713.35	13,905.29
	Holt Winters	6,402.58	12,354.97	216,602.60	22,602.08	25,785.47	13,434.28
	Box & Jenkins		13,109.22	14,339.21	14,855.66	16,333.86	16,940.92
4	Demanda real	2,540.45	5,446.26	11,208.23	8,314.33	12,995.92	8,299.91
	Stepwise	5,910.05	6,568.41	7,226.78	7,885.14	8,543.51	9,201.87
	Holt Winters	2,809.80	6,299.78	13,536.51	10,481.06	16,965.12	10,958.26
	Box & Jenkins		8,521.32	9,194.56	10,529.54	9,859.06	10,943.72
5	Demanda real	1,043.700	6,483.08	6,292.22	7,412.75	1,648.72	7,314.12
	Stepwise	4,552.08	5,028.82	5,505.57	5,982.31	6,459.06	6,935.81
	Holt Winters	1,053.28	6,733.45	6,689.75	8,170.38	1,526.97	8,298.93
	Box & Jenkins		5,680.39	7,455.42	7,393.14	7,758.80	5,877.82
6	Demanda real	976.76	14,770.59	9,503.54	11,846.71	8,045.52	7,403.82
	Stepwise	9,220.05	8,774.87	8,329.68	7,884.50	7,439.31	6,994.13
	Holt Winters	1,765.24	9,285.89	8,536.33	11,925.07	8,347.97	8,277.69
	Box & Jenkins		7,197.41	7,422.30	7,336.43	7,374.63	7,312.66
7	Demanda real	4,908.04	9,895.72	14,712.84	7,579.94	5,384.74	6,087.74
	Stepwise	9,700.13	9,069.74	8,439.35	7,808.96	7,178.57	6,548.18
	Holt Winters	488.00	1,965.24	5,621.36	4,622.15	4,475.94	6,087.73
	Box & Jenkins		5,466.82	8,114.27	10,671.19	6,885.06	5,719.85
8	Demanda real	324.30	1,936.20	3,643.60	1,151.10	1,534.80	1,667.40
	Stepwise	1,212.09	1,583.36	1,954.63	2,325.90	2,697.18	3,068.45
	Holt Winters	371.96	1,909.48	3,815.77	967.81	1,666.78	1,667.40
	Box & Jenkins		2,165.75	2,934.35	3,748.49	2,559.99	2,742.95
9	Demanda real	776.98	4,749.88	3,417.08	3,512.44	1,871.96	1,315.11
	Stepwise	2,834.74	2,822.73	2,810.73	2,798.72	2,786.71	2,774.71
	Holt Winters	834.55	4,651.47	3,565.55	3,597.05	1,921.52	1,368.54
	Box & Jenkins		3,095.35	2,820.46	2,912.68	2,906.08	3,019.59
10	Demanda real	1,264.21	3,709.09	1,819.06	4,787.07	2,619.47	3,121.83
	Stepwise	2,428.36	2,440.62	2,452.88	2,465.13	2,477.39	2,489.65
	Holt Winters	1,342.97	4,124.03	2,110.14	5,762.73	3,249.00	3,927.90
	Box & Jenkins		2,533.99	2,683.21	2,567.85	2,749.00	2,616.71
11	Demanda real	199.25	2,598.67	2,765.60	2,926.11	1,046.00	3,174.49
	Stepwise	1,863.65	1,963.16	2,062.66	2,162.17	2,261.68	2,361.19
	Holt Winters	199.25	2,591.81	2,828.69	3,043.87	1,094.91	3,319.76
	Box & Jenkins		3,078.14	2,575.06	2,540.06	2,506.41	2,900.61
12	Demanda real	2,545.03	4,407.65	8,549.01	3,581.08	2,599.92	3,014.03
	Stepwise	4,945.69	4,477.33	4,008.97	3,540.60	3,072.24	2,603.87
	Holt Winters	2,632.32	4,682.44	9,316.76	4,002.28	2,971.27	3,510.96
	Box & Jenkins		2,344.99	3,442.18	5,881.67	2,955.28	2,377.32
13	Demanda real	500.00	4,700.00	3,800.00	3,300.00	2,900.00	1,900.00
	Stepwise	2,992.48	2,876.29	2,760.09	2,643.90	2,527.70	2,411.51
	Holt Winters	359.25	3,282.90	3,800.00	3,410.66	2,962.79	1,707.15
	Box & Jenkins		2,293.47	2,772.28	2,669.68	2,612.68	2,567.08
14	Demanda real	474.08	4,308.52	3,558.97	2,929.51	2,641.11	1,629.55
	Stepwise	2,919.23	2,804.34	2,689.45	2,574.57	2,459.68	2,344.79
	Holt Winters	928.00	2,088.96	2,517.10	2,481.81	2,488.59	1,401.35
	Box & Jenkins		2,630.92	2,282.55	2,350.65	2,407.83	2,434.04
15	Demanda real	845.92	1,689.83	1,056.35	3,116.10	851.39	1,705.58
	Stepwise	1,245.94	1,388.13	1,530.31	1,672.50	1,814.68	1,956.87
	Holt Winters	948.22	2,174.57	1,474.30	3,958.66	1,313.95	3,078.56
	Box & Jenkins		2,687.30	2,257.82	2,580.21	1,531.98	2,684.51



Tabla 2. Pronósticos de cada método de Diciembre a Junio

NO.	MÉTODO	DICIEMBRE	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO
1	Demanda real	533,019.00	720,733.00	667,198.00	1,850,764.00	1,017,703.00	1,312,513.00	
	Stepwise	1,230,268.00	1,222,787.50	1,215,307.00	1,207,826.50	1,200,346.00	1,192,865.50	1,185,385.00
	Holt Winters	410,952.41	459,438.31	365,584.15	1,555,673.07	895,607.61	1,025,165.85	1,011,621.49
	Box & Jenkins	1,792,440.43	425,707.82	575,629.51	532,872.67	1,478,152.28	812,810.78	1,048,266.92
2	Demanda real	900.00	243,701.00	73,767.00	142,330.00	96,508.00	215,183.00	
	Stepwise	151,107.91	146,870.74	142,633.56	138,396.39	134,159.21	129,922.04	125,684.86
	Holt Winters	1,782.82	147,885.46	62,466.71	79,824.25	70,609.58	207,214.23	113,070.47
	Box & Jenkins	130,700.79	218,050.37	117,773.47	187,956.27	159,639.73	178,564.23	129,551.41
3	Demanda real	13,414.22	3,442.49	2,849.70	24,403.80	16,497.20	15,671.23	
	Stepwise	14,097.24	14,289.19	14,481.13	14,673.08	14,865.02	15,056.97	15,248.91
	Holt Winters	13,121.78	3,444.85	2,849.70	26,785.99	16,497.68	17,383.57	15,039.42
	Box & Jenkins	14,446.21	14,608.31	12,503.21	12,378.07	16,928.29	15,259.15	15,084.78
4	Demanda real	1,124.61	5,675.57	20,725.28	24,108.32	5,618.46	8,315.31	
	Stepwise	9,860.24	10,518.60	11,176.97	11,835.33	12,493.69	13,152.06	13,810.42
	Holt Winters	1,124.60	7,911.67	31,075.84	37,399.48	7,035.91	10,803.94	8,419.34
	Box & Jenkins	9,855.72	8,193.29	9,247.69	12,734.52	13,518.32	9,234.46	9,859.28
5	Demanda real	10,559.30	10,495.89	12,233.17	9,035.40	8,101.48	5,470.33	
	Stepwise	7,412.55	7,889.30	8,366.05	8,842.79	9,319.54	9,796.28	10,273.03
	Holt Winters	12,758.54	13,038.28	16,431.56	11,064.93	9,355.94	5,469.77	3,361.17
	Box & Jenkins	7,726.62	8,785.62	8,764.93	9,331.85	8,288.32	7,983.56	7,124.93
6	Demanda real	3,658.54	4,677.76	5,205.21	5,717.79	7,030.53	2,421.67	
	Stepwise	6,548.94	6,103.76	5,658.57	5,213.39	4,768.20	4,323.02	3,877.84
	Holt Winters	3,470.42	2,681.08	2,825.25	3,084.87	4,751.33	804.12	367.79
	Box & Jenkins	7,302.19	7,241.13	7,257.75	7,266.35	7,274.70	7,296.11	7,220.96
7	Demanda real	7,086.37	4,520.83	5,830.56	3,939.93	2,415.47	2,433.57	
	Stepwise	5,917.78	5,287.39	4,657.00	4,026.61	3,396.22	2,765.83	2,135.44
	Holt Winters	5,520.38	4,668.91	6,069.01	4,231.69	2,411.36	1,447.30	1,042.44
	Box & Jenkins	6,093.00	6,623.07	5,261.29	5,956.49	4,952.94	4,143.77	4,153.37
8	Demanda real	5,692.90	5,245.20	4,164.80	4,601.30	4,856.80	4,230.60	
	Stepwise	3,439.72	3,810.99	4,182.26	4,553.54	4,924.81	5,296.08	5,667.35
	Holt Winters	7,099.15	7,276.27	6,201.77	6,558.86	5,453.84	5,446.58	3,299.35
	Box & Jenkins	2,806.18	4,725.66	4,512.19	3,997.02	4,205.15	4,326.98	4,028.39
9	Demanda real	2,994.22	3,143.86	3,366.61	4,368.73	2,174.38	1,533.22	
	Stepwise	2,762.70	2,750.70	2,738.69	2,726.69	2,714.68	2,702.67	2,690.67
	Holt Winters	3,583.68	3,143.84	3,393.54	4,851.71	2,443.92	1,745.13	2,427.60
	Box & Jenkins	3,058.12	2,941.94	2,931.59	2,916.17	2,846.84	2,998.66	3,043.03
10	Demanda real	385.49	617.29	1,594.88	3,775.46	3,503.81	2,751.66	
	Stepwise	2,501.90	2,514.16	2,526.42	2,538.67	2,550.93	2,563.19	2,575.45
	Holt Winters	385.49	602.32	2,157.25	5,333.25	5,187.41	3,729.61	2,247.88
	Box & Jenkins	2,647.37	2,480.36	2,494.50	2,554.17	2,687.26	2,670.68	2,624.77
11	Demanda real	3,160.89	2,642.12	1,787.12	3,964.41	2,382.68	2,283.94	
	Stepwise	2,460.69	2,560.20	2,659.71	2,759.22	2,858.72	2,958.23	3,057.74
	Holt Winters	3,374.72	2,811.43	2,026.81	4,395.25	2,475.06	2,373.64	912.26
	Box & Jenkins	2,454.33	2,457.18	2,565.95	2,745.22	2,288.71	2,620.35	2,641.05
12	Demanda real	791.05	144.80	467.85	1,433.99	624.60	277.31	
	Stepwise	2,135.51	1,667.15	1,198.78	730.42	262.06	-206.31	-674.67
	Holt Winters	922.50	144.80	530.42	1,798.68	763.02	267.95	181.28
	Box & Jenkins	2,621.26	1,311.80	931.12	1,121.41	1,690.52	1,213.75	1,009.17
13	Demanda real	650.00	1,900.00	2,900.00	2,600.00	2,390.89	700.00	
	Stepwise	2,295.31	2,179.11	2,062.92	1,946.72	1,830.53	1,714.33	1,598.13
	Holt Winters	650.00	2,175.49	2,163.96	1,892.29	1,635.92	215.04	57.82
	Box & Jenkins	2,453.07	2,310.57	2,453.07	2,567.08	2,532.88	2,509.04	2,316.27
14	Demanda real	2,960.67	1,765.54	2,361.26	2,187.74	2,037.06	594.18	
	Stepwise	2,229.91	2,115.02	2,000.13	1,885.25	1,770.36	1,655.47	1,540.59
	Holt Winters	2,254.22	5,205.96	3,820.54	2,816.21	2,275.11	720.76	1,011.47
	Box & Jenkins	2,525.94	2,405.00	2,513.59	2,459.46	2,475.23	2,488.92	2,620.01
15	Demanda real	3,277.17	1,413.83	851.11	5,659.29	767.31	3,101.67	
	Stepwise	2,099.06	2,241.24	2,383.43	2,525.61	2,667.80	2,809.98	2,952.17
	Holt Winters	4,381.25	2,891.57	1,633.68	8,291.47	2,124.86	5,406.71	2,646.96
	Box & Jenkins	2,249.81	1,450.02	2,398.28	2,684.66	237.73	2,727.30	1,539.33



RESULTADOS Y DISCUSIÓN

Al probar diferentes métodos, podemos encontrar que uno funciona mejor en un contexto específico y otro en un contexto diferente. La validación usando métricas como el MAE o MSE ayuda a identificar el modelo más adecuado para cada caso.

De acuerdo con lo anterior, se evaluó el desempeño usando métricas de Error Absoluto Medio (MAE) y Error Cuadrático Medio (MSE). En las tablas 3 y 4, se comparan los errores de cada producto con los tres métodos de pronóstico utilizados, en ambos casos tenemos el error más bajo resaltado.

Tabla 3. Error Absoluto Medio

	Stepwise	Holt Winters	Box & Jenkins
1	521337.33	158900.86	635637.85
2	71810.72	35206.17	68805.34
3	5341.76	1182.34	5008.48
4	5114.06	3502.45	5091.26
5	2310.46	1228.85	1867.24
6	2485.74	1632.46	2713.95
7	1573.60	2378.61	2356.00
8	962.83	817.22	976.63
9	1023.64	172.74	898.25
10	1123.80	666.06	1094.23
11	817.17	134.80	555.48
12	1090.07	260.48	1476.14
13	990.46	406.94	878.50
14	761.86	928.59	763.80
15	1058.13	1111.85	989.42

Tabla 4. Error Cuadrático Medio

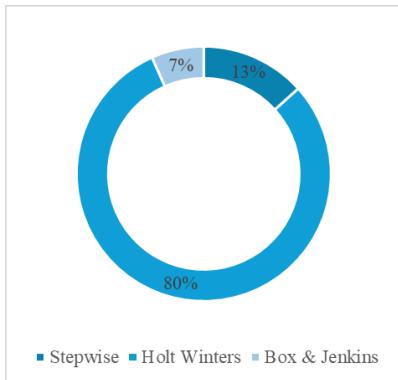
	Stepwise	Holt Winters	Box & Jenkins
1	3.23278E+11	34395618723	5.91299E+11
2	6950534335	2506674955	6331941286
3	48327024.62	4392916.25	44978836.21
4	38459401.08	27560809.32	40197274.42
5	7688058.95	3033253.40	6437342.15
6	11757844.63	4744180.89	12069408.83
7	5907963.85	14853969.28	8568979.28
8	1394643.85	1333563.34	1730258.71
9	1395901.48	62210.12	1124682.70
10	1716288.43	732930.77	1716886.82
11	815277.31	31286.40	488314.83
12	2691053.95	117354.87	3926872.15
13	1392151.65	333752.10	1335062.27
14	978615.21	1785539.51	905206.99
15	1790681.67	1777392.10	1533338.43

Se puede apreciar en el producto 14 (ver tabla 3 y 4) que el error más bajo es diferente, sin embargo, se prefiere una métrica más interpretable y menos sensible a valores atípicos, por lo que el Error Absoluto Medio (MAE) puede ser la mejor opción.

Con lo anterior se puede determinar que el método de Holt-Winters es más preciso en el 80% de los casos (ver ilustración 1).

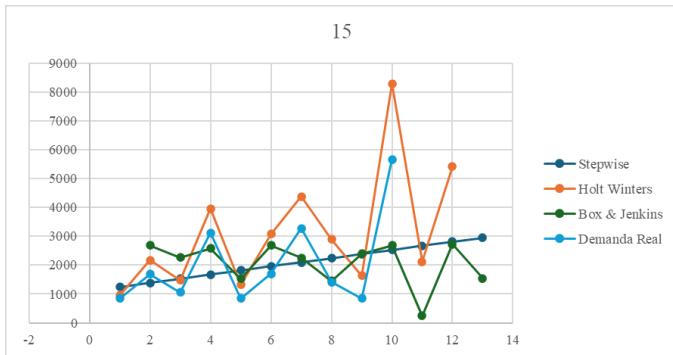
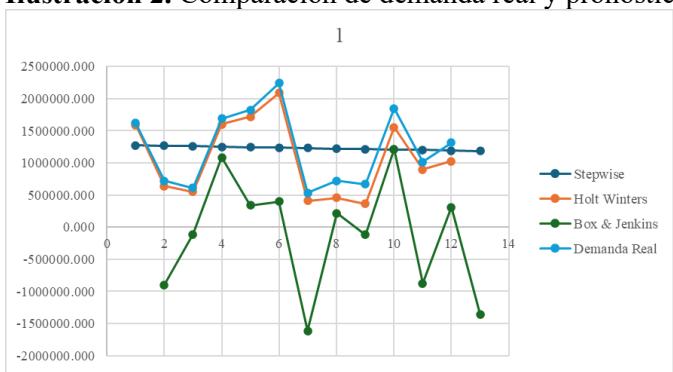


Ilustración 1. Precisión de cada método



Además, en la ilustración 2 se aprecia la comparación de la demanda de consumo real del artículo 1 y 15 con los pronósticos de los tres métodos, donde nos podemos dar cuenta que cada artículo requiere un diferente método de acuerdo con sus patrones, tendencias o estacionalidad. Es decir, la elección del método adecuado depende de varios factores que pueden variar significativamente entre escenarios, pero el que más se ajusta sigue siendo Holt-Winters.

Ilustración 2. Comparación de demanda real y pronósticos



Por otro lado, se puede observar el pronóstico del mes de junio del artículo número 12 en el método de Stepwise (ver tabla 2), como nos podemos dar cuenta el resultado es negativo, debido a que el artículo

tiene un coeficiente de correlación negativo, es decir, presenta una baja, por lo cual no es conveniente seguir comprando este producto.

CONCLUSIONES

En conclusión, no todos los métodos de pronóstico son igualmente efectivos en todas las situaciones. Por eso, es importante analizar las características de los datos, el horizonte de tiempo y los objetivos específicos antes de seleccionar el método más adecuado. Esto garantiza que el pronóstico sea preciso, relevante y útil para la toma de decisiones.

Como vimos el método Stepwise se utiliza para construir modelos que seleccionen de manera iterativa las variables más relevantes, puede identificar automáticamente las variables predictoras más importantes, reduciendo el riesgo de sobreajuste, es útil cuando hay un gran número de variables independientes y no se sabe cuáles son las más influyentes, pero no es adecuado para datos con estacionalidad o patrones de series temporales. El método Holt Winters es una excelente opción para datos con patrones de tendencia y estacionalidad bien definidos, pero no se recomienda si los datos son altamente aleatorios o no tienen estacionalidad. Finalmente, el método Box & Jenkins es uno de los métodos más robustos para datos de series temporales sin estacionalidad o con estacionalidad compleja, pero puede ser excesivo para datos simples.

Además, durante el desarrollo del artículo nos dimos cuenta de que los pronósticos no solo son herramientas valiosas para planificar compras, también, permiten analizar el comportamiento de nuestros productos a lo largo del tiempo. De este modo, se puede determinar con mayor precisión si es prudente continuar adquiriendo ciertos productos o si es momento de ajustar el portafolio, optimizando así los recursos y mejorando la eficiencia del negocio.

REFERENCIAS BIBLIOGRÁFICAS

biblus. (s.f.). Obtenido de biblus:

https://biblus.us.es/bibing/proyectos/use/abreproy//fichero/3452%252F4_Metodos_Prevision.pdf

Caballero, M. M. (19 de Octubre de 2023). linkedin. Obtenido de linkedin:

<https://es.linkedin.com/pulse/tiempedia-modelos-de-suavizamiento-exponencial-mora-caballero-pdn1e>



Caballero, M. M. (20 de Noviembre de 2023). Linkedin. Obtenido de Linkedin:

<https://es.linkedin.com/pulse/tiempedia-evaluaci%C3%B3n-y-m%C3%A9tricas-de-rendimiento-en-mora-caballero-u5wpe>

Ch., A. A. (s.f.). ipn.mx. Obtenido de ipn.mx: <https://www.ipn.mx/assets/files/investigacion-administrativa/docs/revistas/23/ART4.pdf>

Chatfield, C. (2000). Time series forecasting. Chapman & Hall/CRC.

Chinlli, C. M. (2021). masteres.ugr. Obtenido de masteres.ugr: https://masteres.ugr.es/estadistica-aplicada/sites/master/moea/public/inline-files/TFM_MIRANDA_CHINLLI_CARLOS.pdf

Comm, J. (19 de Septiembre de 2024). ADOGY. Obtenido de ADOGY:

<https://www.adogy.com/es/terms/forecast-accuracy/>

Corte, A. G. (Junio de 2016).

Douglas C. Montgomery, C. L. (2015). Time series analysis and forecasting. Wiley.

fastercapital. (s.f.). Obtenido de fastercapital: <https://fastercapital.com/es/tema/introducci%C3%B3n-al-suavizado-exponencial.html>

FasterCapital. (24 de Junio de 2024). Obtenido de FasterCapital:

<https://fastercapital.com/es/contenido/Proceso-de-prevision-financiera--como-disenar-e-implementar-el-proceso-de-prevision-financiera-para-su-negocio.html#Evaluaci-n-de-la-precision-de-los-pron-sticos.html>

Fernández, S. d. (s.f.). Estadística.net. Obtenido de

<https://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>

Gonzalez, J. M. (13 de Octubre de 2019). RPubs. Obtenido de

https://rpubs.com/jorge_mendez/609253

Ling Romero, M. Y., & Aylas Bendezú, J. P. (8 de Julio de 2023). repositorioacademico.upc. Obtenido de repositorioacademico.upc:

https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/673735/Ling_RM.pdf;jsessionid=65153DE7F9CFAF2BA02804D6612E5202?sequence=1

Madrigal, E. (28 de Octubre de 2022). growup. Obtenido de growup:

<https://www.growupcr.com/post/metricas-precision>



Mauricio, J. A. (Marzo de 2007). ucm.es. Obtenido de ucm.es:

<https://www.ucm.es/data/cont/docs/518-2013-11-11-JAM-IAST-Libro.pdf>

netlogistik. (2024). Obtenido de netlogistik: <https://www.netlogistik.com/es/blog/como-llevar-a-cabo-un-pronostico-de-la-demanda>

Parra, R. (14 de Marzo de 2023). Linkedin. Obtenido de <https://es.linkedin.com/pulse/triple-suavido-exponencial-o-metodo-de-holt-winters-raul>

Rob J Hyndman, G. A. (2018). Forecasting principles and practice. Melbourne, Australia: OTexts.

Sabando-García, A. R. (Enero de 2022). Revista Ingeniería, Investigación y Desarrollo. Obtenido de Revista Ingeniería, Investigación y Desarrollo:

