

Aplicación de modelos cuantitativos ARIMA utilizando el software R para la planificación de la producción en entornos industriales

Application of ARIMA quantitative models using R software for production planning in industrial environments

Juan Diego Erazo Rodríguez*
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
juan.erazo@esPOCH.edu.ec
<https://orcid.org/0000-0003-0152-5645>

Vanessa Lorena Valverde González
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
v_valverde@esPOCH.edu.ec
<https://orcid.org/0000-0002-3501-8353>

Raúl Gregorio Martínez Pérez
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
raul.martinez@esPOCH.edu.ec
<https://orcid.org/0000-0002-1552-7580>

Javier Edmundo Albuja Jácome
Escuela Superior Politécnica de Chimborazo
Riobamba - Ecuador
javier.albuja@esPOCH.edu.ec
<https://orcid.org/0009-0005-5044-3373>

*Correspondencia:
juan.erazo@esPOCH.edu.ec

Cómo citar este artículo:
Erazo, J., Valverde, V., Martínez, R., & Albuja, J. (2026). Aplicación de modelos cuantitativos ARIMA utilizando el software R para la planificación de la producción en entornos industriales. *Esprint Investigación*, 5(1), 964-982. <https://doi.org/10.61347/ei.v5i1.317>

Recibido: 8 de mayo de 2026
Aceptado: 11 de junio de 2026
Publicado: 16 de junio de 2026

Copyright: Derechos de autor 2026 Juan Diego Erazo Rodríguez, Vanessa Lorena Valverde González, Raúl Gregorio Martínez Pérez, Javier Edmundo Albuja Jácome.



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

Resumen: El presente estudio aborda el modelado y pronóstico de la demanda mensual en un entorno de manufactura, en el marco del Plan de Planificación y Control de la Producción. La unidad de análisis correspondió a una serie univariada de demanda operativa registrada durante 24 meses, representativa de un proceso productivo con comportamiento estable y periodicidad regular. La investigación adoptó una perspectiva cuantitativa y aplicada, con un diseño longitudinal no experimental, centrado en el examen estructural de la secuencia temporal y la validación estadística de un modelo parsimonioso. Se implementaron modelos ARIMA como herramienta metodológica adecuada para entornos fabriles con enfoque de medio plazo. El manejo de la serie incluyó la verificación de la calidad de los datos, la evaluación de la estacionalidad y la ejecución de pruebas de estacionariedad (ADF, KPSS y OCSB), además del análisis de las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) para identificar los grados de dependencia temporal. Los resultados evidenciaron que no era necesario aplicar diferenciación, lo que condujo a la selección de un modelo ARMA(0,1) estimado mediante máxima verosimilitud. Este modelo mostró un desempeño superior frente al modelo Naïve, con una mejora del 45 % en el MAPE, cumpliendo además con los supuestos de independencia, normalidad y homocedasticidad de los residuos. Finalmente, el modelo fue reestimado con la serie completa para generar una previsión operativa de seis meses con intervalos de confianza del 80 % y 95 %, útil para la definición de puntos de pedido y estrategias de inventario. Los resultados evidencian que un modelo ARMA parsimonioso proporciona precisión, trazabilidad y gobernanza operativa, fortaleciendo la planificación de la producción y la estabilidad de la cadena de suministro.

Palabras clave: ARIMA, ARMA, cadena de suministro, producción, pronósticos.

Abstract: This study addresses the modeling and forecasting of monthly demand in a manufacturing environment within the framework of the Production Planning and Control (PPC) system. The unit of analysis consisted of a univariate time series of operational demand recorded over 24 months, representing a production process with stable behavior and regular periodicity. The research adopted a quantitative and applied approach with a non-experimental longitudinal design, focused on the structural examination of the time series and the statistical validation of a parsimonious model. ARIMA models were implemented as an appropriate methodological tool for manufacturing environments with a medium-term forecasting horizon. The data handling process included data quality verification, seasonality assessment, and the application of stationarity tests (ADF, KPSS, and OCSB), as well as the analysis of autocorrelation (ACF) and partial autocorrelation (PACF) functions to identify dependency structures. The results showed that differencing was not required, leading to the selection of an ARMA(0,1) model estimated via maximum likelihood. This model outperformed the Naïve benchmark, achieving a 45% improvement in MAPE, while also satisfying the assumptions of independence, normality, and homoscedasticity of residuals. Finally, the model was re-estimated using the full dataset to generate a six-month operational forecast with 80% and 95% confidence intervals, useful for defining reorder points and inventory strategies. The findings demonstrate that a parsimonious ARMA model provides accuracy, traceability, and operational governance, strengthening production planning and supply chain stability.

Keywords: ARIMA, ARMA, forecasts, production, supply chain.

1. Introducción

La planificación y el control de la producción exigen señales de demanda confiables para sincronizar abastecimiento, capacidad e inventarios, minimizando el efecto látigo y el costo total. Dentro de este contexto, los modelos ARIMA proporcionan un marco de trabajo eficiente y fácil de analizar para identificar tendencias, autocorrelación y variaciones estacionales con seguimiento práctico (Fattah et al., 2018).

En el ámbito de la gestión de inventario y el procesamiento de pedidos, ARIMA muestra un rendimiento sólido y consistente cuando la planificación es a corto plazo y la transparencia es clave para la implementación y el mantenimiento del sistema de predicción (Wang et al., 2021). Estudios comparativos recientes muestran que ARIMA es una referencia sólida frente a métodos de aprendizaje automático. La elección del modelo depende del comportamiento de los datos, el horizonte de predicción y el impacto del error en métricas como MAE, RMSE o MAPE (Makridakis et al., 2020).

Aparte de esto, en sectores de la cadena de suministro, los modelos ARIMA generan información útil para la negociación, la planificación presupuestaria y las adquisiciones. Esto influye directamente en la planificación general y en la estrategia de inventario (Goltsos et al., 2022). Pese a estos avances, aún existen vacíos prácticos. Con frecuencia se reporta la precisión del pronóstico sin traducirla en reglas de reabastecimiento ni documentar completamente los diagnósticos del modelo que sustentan su validez.

Para abordar estos vacíos, el presente artículo articula una revisión narrativa estructurada de la evidencia reciente junto con un estudio empírico en datos reales. En este proceso se estimó y validó un ARIMA, que para este caso específico derivó en un modelo ARMA. Posteriormente, se conecta la señal obtenida con decisiones de planificación e inventario mediante tablas y figuras reproducibles. El objetivo general es demostrar, con evidencia aplicada, que un modelo correctamente identificado y diagnosticado puede optimizar decisiones de producción, mejorar la precisión de la demanda y reducir costos de inventario y nivel de servicio (Wang et al., 2021).

Background

En este sentido, los modelos ARIMA ofrecen un marco simple que separa tendencia, autocorrelación y estacionalidad. Además, proporcionan herramientas diagnósticas claras como análisis de residuos, pruebas de autocorrelación y criterios de información. Esto facilita la supervisión del modelo en contextos operativos. Los estudios señalan que, cuando la dinámica temporal es principalmente lineal y estacional, ARIMA es adecuado para el medio plazo. Bajo estas condiciones, puede generar pronósticos sólidos con un seguimiento metodológico claro. Por ello, se considera un modelo de referencia en el sector industrial (Fattah et al., 2018).

En gestión de la cadena de suministro, un ARIMA bien calibrado mejora estrategias de inventario y gestión de pedidos. Esto es especialmente útil en sistemas de previsión continua donde se requiere simplicidad y facilidad de mantenimiento. En fabricación y distribución, ARIMA puede ser comparable a métodos más complejos si se maneja adecuadamente la estacionalidad. Indicadores como MAE, RMSE y MAPE, junto con validación temporal, permiten evaluar su desempeño de forma realista.

Esta combinación permite usar ARIMA como modelo base y, mediante SARIMA, analizar patrones cíclicos definidos (Wang et al., 2021; Chen et al., 2000). Además, existen aplicaciones que influyen directamente en decisiones operativas de la cadena de suministro. ARIMA actúa como puente entre la predicción y la toma de decisiones.

En transporte por carretera, su uso en precios mensuales permite proyectar tendencias para presupuestos y negociaciones. Esto impacta en costos logísticos y decisiones de capacidad. En el sector agroalimentario, ARIMA ayuda a prever precios de productos básicos ante perturbaciones externas. Esto apoya la planificación de compras y reduce la inestabilidad del suministro. Finalmente, en el comercio minorista, se han desarrollado sistemas de predicción que consideran efectos de sustitución entre productos. En estos casos, ARIMA funciona como referencia interpretativa frente a modelos más complejos (Ali et al., 2012).

2. Metodología

Diseño metodológico y revisión de evidencia

Este estudio adopta un diseño de investigación aplicada con enfoque cuantitativo, desarrollando un estudio empírico reproducible que identifica, estima, diagnostica y opera un modelo ARIMA sobre una serie temporal real de demanda, con el objetivo explícito de traducir la señal de pronóstico a reglas operativas de reabastecimiento y programación de la producción. Con el objetivo de guiar las decisiones metodológicas en este caso práctico, y no como un análisis sistemático en sentido estricto, la revisión adoptó un esquema de identificación, selección y evaluación similar a la metodología PRISMA. Esto permitió asegurar la claridad documental del proceso, aunque sin llegar a una síntesis cuantitativa.

El área de análisis se enmarca en las cadenas de suministro del sector manufacturero, donde la demanda operativa se registra con periodicidad regular y constituye un insumo fundamental para la planificación y control de la producción, así como la planificación de requerimientos de materiales (MRP); de esta forma se identificó, la unidad empírica de estudio corresponde a una serie temporal univariada de demanda mensual con 24 observaciones, obtenida de una empresa manufacturera representativa del sector la cual presenta adecuadamente las dinámicas típicas del sector en términos de estacionalidad y comportamiento operativo.

Optar por una sola fuente de datos empíricos se basa en que sea representativa, estable y que ofrezca datos a largo plazo. Esto ayuda a identificar tendencias importantes en los cambios y el estado, sin que las diferencias entre organizaciones distorsionen los resultados. Este enfoque metodológico facilita la comprensión y el control del modelo, cualidades vitales para llevarlo a la práctica. Allí, los datos de demanda deben convertirse en normas de reposición y planificación, considerando los límites reales de precio y calidad del servicio (De Gooijer & Hyndman, 2006).

La evidencia empírica y teórica revisada sustenta que, en horizontes tácticos con presencia de estacionalidad, los modelos ARIMA, ARMA y SARIMA logran un equilibrio sólido entre precisión predictiva, transparencia y auditabilidad, justificando su elección como eje metodológico del estudio (Wang & Disney, 2016).

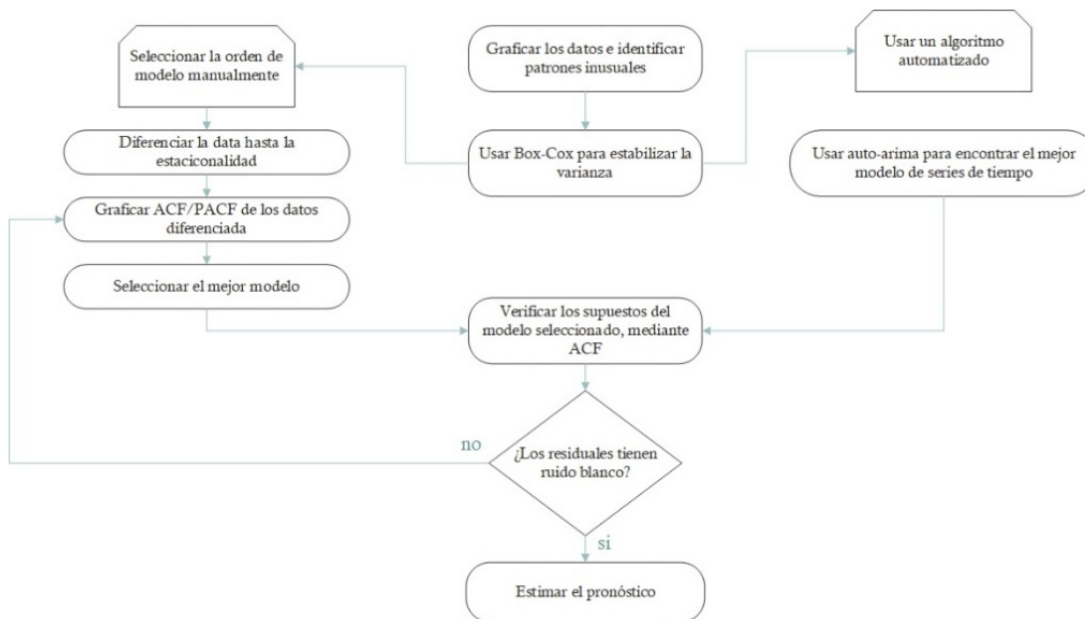
La cantidad solicitada de artículos o su valor monetario, captada a espacios de tiempo regulares, representa la variable a explicar. Los factores que influyen en ella se encuentran integrados dentro del modelo ARIMA, utilizando datos pasados, ajustes por tendencias y promedios móviles de errores, incluyendo patrones cíclicos si son relevantes. Para juzgar qué tan bien funciona el modelo, se usan medidas como el error absoluto medio, la raíz del error cuadrático medio y el error porcentual absoluto medio, probándolo con datos de diferentes periodos y eligiendo la versión más sencilla según criterios de información. Esta configuración garantiza que las métricas de error puedan traducirse a costo operativo, vinculando la precisión del pronóstico con decisiones de inventario y nivel de servicio.

Proceso de modelado y selección del modelo

La gestión de una serie temporal para la planificación y control de la producción (PCP) inicia con una inspección cuidadosa de calidad de datos y periodicidad donde se corrigen ausentes, se definen frecuencia, horizonte y se visualizan niveles, tendencia y estacionalidad; a continuación se estabiliza la varianza mediante transformaciones de potencia Box – Cox; a fin de favorecer la aditividad y el control de la heterocedasticidad, lo que prepara la serie para la identificación estructural de ARIMA y de su contraparte estacional SARIMA cuando existe estacionalidad marcada (Box & Cox, 1964) (figura 1).

Figura 1

Diagrama del flujo del modelado ARIMA



Nota. Fuente autor a partir de la explicación de la metodología de Box et al. (2015).

La gestión de una serie temporal para PCP inicia con una inspección cuidadosa de calidad de datos y periodicidad donde se corrigen ausentes, se definen frecuencia, horizonte y se visualizan niveles, tendencia y estacionalidad; a continuación se estabiliza la varianza cuando corresponde mediante transformaciones de potencia como Box & Cox a fin de favorecer la aditividad y el control de la heterocedasticidad, lo que prepara la serie para la identificación estructural de ARIMA y de su contraparte estacional SARIMA cuando existe estacionalidad marcada (Box & Cox, 1964).

La estacionariedad se contrasta de forma complementaria con pruebas de raíz unitaria y de estacionariedad en tendencia, por ejemplo, con Dickey & Fuller aumentado para evaluar la presencia de raíz unitaria y con KPSS para verificar la hipótesis de estacionariedad, de modo que la combinación de ambos resultados guíe el grado de diferenciación necesario tanto no estacional como estacional antes de proceder a la selección de órdenes (Dickey & Fuller, 1979; Kwiatkowski et al., 1992).

La determinación precisa de los términos autorregresivos y de medias móviles se realiza combinando el análisis visual de las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) con una búsqueda automatizada supervisada. Este proceso compara diferentes especificaciones del modelo según criterios de información ajustados y el desempeño predictivo obtenido mediante validación temporal de tipo rolling origin. De esta forma, se minimiza el riesgo de sobreajuste y se prioriza la parsimonia, favoreciendo su aplicación práctica en entornos productivos.

En la práctica, esta etapa suele implementarse mediante algoritmos como los incorporados en la función `auto.arima()` del software R, los cuales exploran de manera secuencial las combinaciones posibles de órdenes y penalizan la complejidad del modelo a través del AICc, con una reoptimización posterior por máxima verosimilitud (Hyndman & Khandakar, 2008).

Una vez identificado el modelo candidato, se realiza un diagnóstico exhaustivo de los residuos para comprobar la validez estadística del ajuste. Este examen incluye la prueba de (Ljung & Box, 1978), la revisión de la ACF de los residuos y la verificación de la estabilidad de los parámetros a lo largo del tiempo. Si se detecta dependencia serial o una especificación inadecuada, el proceso de identificación se repite con órdenes alternativos o con diferenciación adicional hasta conseguir residuos equivalentes a ruido blanco, condición esencial para generar pronósticos confiables y trazables (Ljung & Box, 1978).

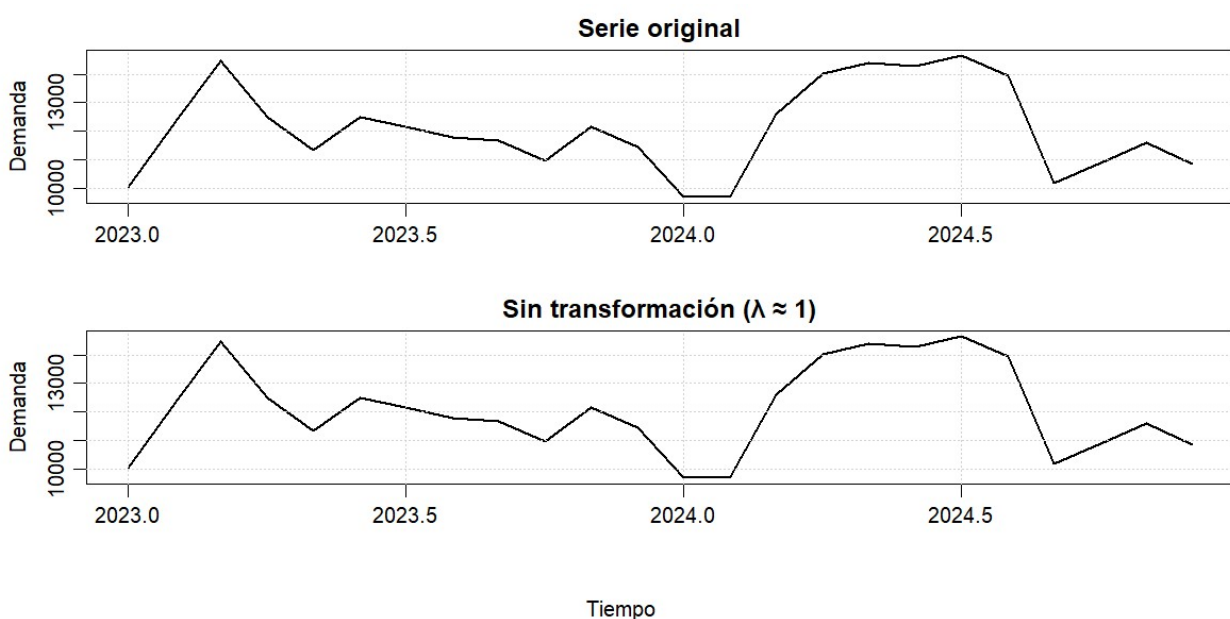
Estabilización de varianza mediante Box–Cox

Una vez, finalizada la limpieza de datos, se evaluó la necesidad de analizar la posibilidad de estabilizar la varianza antes de la identificación del modelo. Para ello se estimó el parámetro de la transformación de Box & Cox, sobre la serie mensual y se generó una visualización comparativa entre la escala original y la escala transformada. El valor estimado de $\lambda=0.9774$, resultó cercano a la unidad, de modo que la transformación no aportó cambios apreciables en la amplitud de las oscilaciones ni en la homogeneidad del error; en consecuencia, se decidió continuar el análisis en escala original.

Esta decisión es operativamente deseable porque evita introducir un paso de transformación innecesaria, que podría complicar la comunicación de resultados a áreas no técnicas, manteniendo la trazabilidad directa entre la señal de pronóstico y las magnitudes de demanda que utilizan los responsables de planificación y control de la producción. La evidencia visual que sustenta la decisión se reportó en la figura 2, donde se puede verificar que ambas trayectorias son prácticamente indistinguibles, lo que confirma la estabilidad relativa de la varianza en el horizonte de interés.

Figura 2

Serie original no transformada



Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Desde el punto de vista metodológico, se dejó documentado el valor numérico de $\lambda=0.9974$, ya que esa trazabilidad posibilita reproducir el análisis en contextos distintos y facilita auditorías posteriores. Para este caso, la transformación no se aplica porque el beneficio potencial es marginal frente al costo de complejidad adicional.

Esta bitácora de decisiones se empleó de manera consistente a lo largo del estudio para preservar la parsimonia del flujo, una práctica alineada con entornos industriales en los que se privilegia la interpretabilidad del modelo y la facilidad de mantenimiento. Con ello, la serie de trabajo para las etapas siguientes con la descomposición de la serie, pruebas de estacionariedad e identificación y permaneció en la misma escala que emplean los procesos de planificación e inventarios, lo que simplificó más adelante la traducción del pronóstico a reglas operativas.

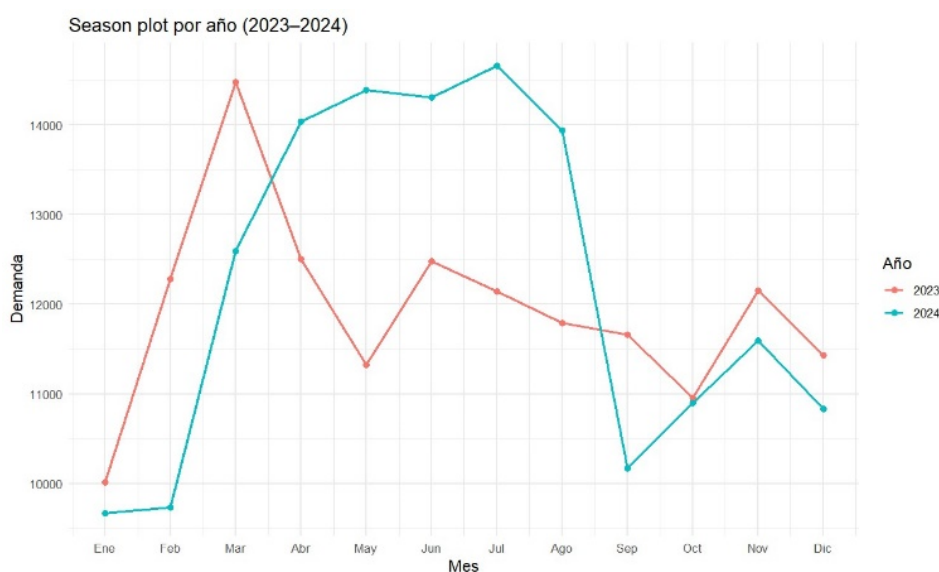
Estructura de la serie y evaluación de estacionariedad

La serie de demanda (2023–2024) se analizó mediante un conjunto complementario de procedimientos gráficos y pruebas formales. Dado que el horizonte de observación abarca únicamente veinticuatro meses, no se aplicó una descomposición clásica en tendencia, ciclo y componente irregular, ya que la extensión temporal no permite identificar con estabilidad un patrón estacional completo. En su lugar, se emplearon herramientas gráficas y contrastes estadísticos que permiten evaluar indirectamente la estructura temporal y la presencia de estacionariedad.

En primer lugar, se inspeccionó la estacionalidad visual mediante la figura 3 y el promedio de la demanda en los dos años, mediante la figura 4. Estas muestran discrepancias interanuales entre abril y agosto de 2023 frente a 2024, lo que sugiere una estacionalidad débil o inestable, sin repetición sistemática de picos o valles. Este comportamiento visual anticipa que no existe una periodicidad regular de orden doce, por lo que la inclusión de un componente estacional SARIMA podría inducir sobre parametrización.

Figura 3

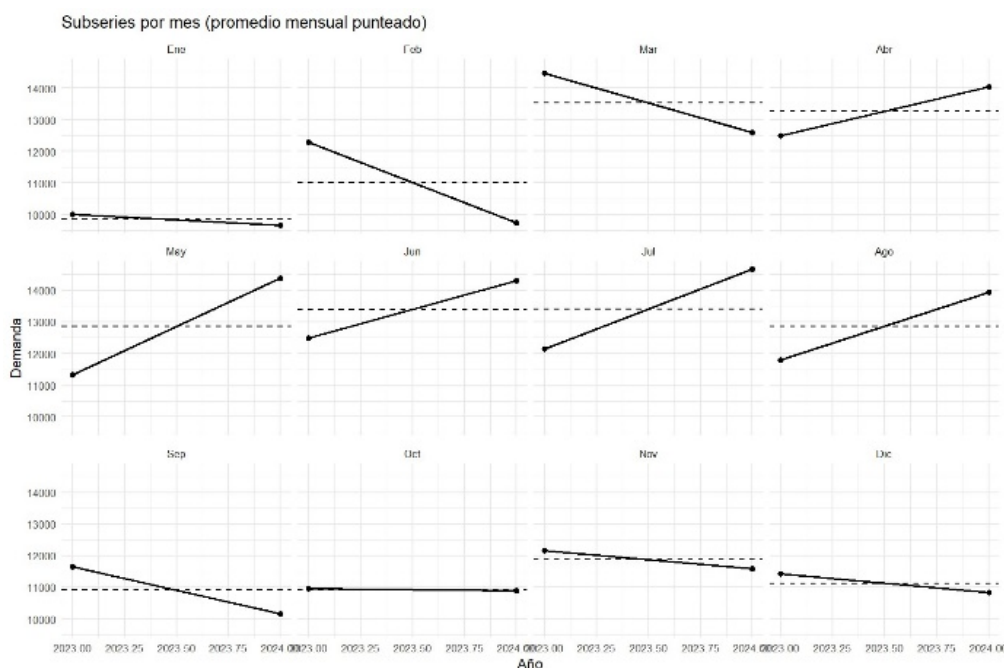
Estacionalidad visual



Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Figura 4

Promedio de la demanda 2023-2024



Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

En segundo lugar, se aplicaron tres pruebas formales para contrastar la estacionariedad de la serie, cuyos indicadores estadísticos fueron exportados directamente desde R y se presentan en la figura 5.

Figura 5

Resultados de las pruebas ADF, KPSS y OCSB exportados desde R

```

--- DECISIÓN DE DIFERENCIACIÓN ---
> cat("ADF p =", signif(p_adf,4), "| KPSS p =", signif(p_kpss,4),
+     "=> d =", d, "\n")
ADF p = 0.6769 | KPSS p = 0.1 => d = 0
> cat("OCSB (m=12) => D =", D, "\n")
OCSB (m=12) => D = 0

```

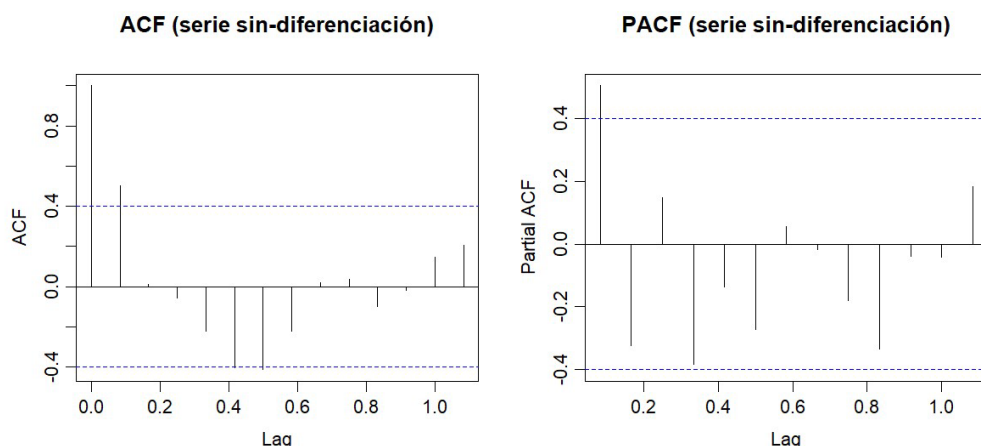
Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

La prueba de Dickey & Fuller aumentado (ADF) se aplicó para contrastar la hipótesis nula de existencia de raíz unitaria. El estadístico obtenido ($p = 0.677$) no permitió rechazar dicha hipótesis, lo que indica que la serie podría presentar no estacionariedad en tendencia.

Por otro lado, la prueba de Kwiatkowski et al., 1992 (KPSS), cuya hipótesis nula plantea estacionariedad en nivel, arrojó un valor p de 0.100, sin evidencia suficiente para rechazar la estabilidad del proceso. De manera complementaria, la prueba OCSB (Osborn et al., 1988), utilizado para verificar la necesidad de diferenciación estacional con una periodicidad de $m = 12$, devolvió un resultado de $D = 0$, por lo que no se recomienda aplicar diferenciación estacional.

La interpretación conjunta de las pruebas conforma un escenario intermedio: el contraste ADF sugiere la posible presencia de no estacionariedad, mientras que los resultados de KPSS y OCSB indican cierta estabilidad en el nivel de la serie. Ante esta evidencia mixta, se optó por aplicar el principio de diferenciación mínima suficiente, privilegiando la parsimonia del modelo y evitando la sobre-diferenciación, especialmente en muestras de tamaño reducido.

El análisis de los correlogramas ACF y PACF (véase figura 6) confirmó este diagnóstico preliminar. En ellos se observa una rápida atenuación de la ACF tras los primeros rezagos y un pico destacado en el PACF correspondiente al primer retardo, comportamiento típico de un proceso ARMA de orden bajo y coherente con una estructura estacionaria. En consecuencia, se establecieron los parámetros $d = 0$ y $D = 0$ para el modelo final.

Figura 6*Correlogramas ACF/PACF*

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Los resultados combinados de las pruebas ADF, KPSS y OCSB no aportaron evidencia suficiente que justificara aplicar diferenciación, ni en su componente estacional ni en el no estacional ($d = 0$, $D = 0$). Este comportamiento permitió considerar la serie como estacionaria en nivel, lo que hizo innecesario modificar su escala original.

Se decidió, por tanto, conservar los datos sin transformaciones diferenciales, con el fin de evitar la pérdida de información relevante sobre la dinámica real de la demanda. Esta elección metodológica condujo a la adopción de un modelo ARMA (Autoregressive Moving Average), adecuado para describir de manera parsimoniosa las dependencias de corto plazo sin distorsionar la estructura temporal inherente al proceso.

En el ámbito de la planificación y control de la producción, mantener la señal original es esencial para garantizar que los pronósticos resulten trazables y puedan emplearse directamente en la programación y el abastecimiento operativo.

Validación temporal y criterio de evaluación del modelo

Tras confirmarse la estacionariedad de la serie ($d = 0$, $D = 0$), se procedió con la fase de identificación y validación del modelo. La validación temporal se llevó a cabo aplicando una estrategia de ventana de retención, en la cual se reservaron los últimos seis meses de observaciones como conjunto de prueba. Este procedimiento simula con mayor realismo el uso operativo del pronóstico dentro de la planificación y control de la producción, ya que las decisiones se toman a partir de la información disponible hasta el momento de la planificación.

El desempeño predictivo del modelo se evaluó mediante los indicadores MAE, RMSE y MAPE, que cuantifican, respectivamente, la magnitud media del error, su raíz cuadrática y el porcentaje de error relativo. Esta metodología permite comprobar la capacidad del modelo para generalizar sin incurrir

en sobreajuste y, al mismo tiempo, preservar la parsimonia necesaria para mantener la coherencia con la naturaleza operativa de los datos analizados.

La figura 7 presenta las métricas de desempeño obtenidas para el modelo ARMA (0,0,1) sobre la ventana de entrenamiento y la ventana de prueba. Se observa un error medio absoluto (MAE) de 1,452.88 unidades y un error porcentual medio absoluto (MAPE) de 12.11 %, valores que reflejan un nivel de ajuste adecuado para la escala operativa de la demanda. El estadístico de Theil's U = 0.837 confirma una precisión superior al pronóstico naïve, lo que valida la capacidad predictiva del modelo en el horizonte considerado.

Figura 7

Métricas de desempeño ARMA (0,0,1)

```
> # Pronóstico en test y métricas
> fc_test <- forecast(fit_auto, h = length(test))
> acc_test <- accuracy(fc_test, test)
> acc_test
```

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	29.38426	1024.680	894.4244	-0.6278233	7.53215	0.4791987	0.1083518	NA
Test set	-171.50093	1546.881	1452.8776	-3.1509748	12.11000	0.7783968	0.2342478	0.8374872

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Posteriormente, se implementó una búsqueda automatizada supervisada utilizando la función `auto.arima()` del entorno R, con la restricción de mantener los parámetros diferenciales fijados en cero ($d = 0, D = 0$), tal como se justificó en la sección anterior. La búsqueda exhaustiva sin aproximaciones permitió explorar combinaciones de órdenes autorregresivos y de medias móviles bajo el criterio de información corregido (AICc).

El primer modelo candidato obtenido correspondió a una configuración ARMA(0,0,1) con media distinta de cero, cuyos parámetros estimados y criterios de ajuste se presentan en la figura 8. El coeficiente del componente MA(1) resultó significativo ($\theta_1 = 0.879$, $p < 0.05$), indicando una dependencia temporal de corto plazo positiva. El logaritmo de la verosimilitud (-151.06) y los valores de AIC = 308.11, AICc = 309.83 y BIC = 310.79 evidencian un buen equilibrio entre ajuste y complejidad.

Figura 8

Ajuste del modelo ARMA(0,0,1) y estimación de parámetros exportados desde R

```
> fit_auto
Series: train
ARIMA(0,0,1) with non-zero mean

Coefficients:
      ma1      mean
  0.8793 12090.5339
s.e.  0.1632   442.7143

sigma^2 = 1181216: log likelihood = -151.06
AIC=308.11 AICc=309.83 BIC=310.79
```

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Con el objetivo de garantizar estabilidad en la elección, se examinó un vecindario de órdenes alrededor del modelo inicial, evaluando distintas combinaciones (p,q) en el rango [0,2]. Para cada especificación se calcularon los valores de AICc, MAE, RMSE y MAPE, tanto en la ventana de entrenamiento como en la de prueba. Los diez mejores resultados se sintetizan en la figura 9, ordenados por AICc.

Esta comparación permitió verificar la robustez del modelo ARMA(0,0,1), el cual mostró un rendimiento competitivo (MAPE = 12.11 %, RMSE = 1546.88) frente a modelos de mayor orden, confirmando que la adición de parámetros no mejoraba sustancialmente la precisión del pronóstico. Por tanto, se seleccionó dicho modelo por su parsimonia, interpretabilidad y estabilidad, atributos prioritarios en el ámbito del PCP, donde la previsión debe integrarse a sistemas de decisión sobre inventarios, capacidad y programación de la producción.

Figura 9

Modelos ARMA(p,q) candidatos ordenados por AICc

p	d	q	AICc	MAE	RMSE	MAPE
1	0	0	309.8293	1452.878	1546.881	12.11000
2	0	0	311.9005	1319.013	1390.297	11.18835
3	1	0	312.5969	1369.431	1447.797	11.54848
4	1	0	315.2149	1322.321	1395.790	11.23545
5	1	0	315.8445	1367.576	1456.283	11.85644
6	0	0	318.2698	1553.352	1681.961	12.82155

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Evaluación comparativa con modelo de referencia

Con el fin de verificar la utilidad práctica del modelo ARMA(0,0,1), se realizó una comparación frente a un modelo de referencia ingenuo (*Naïve forecast*), que replica la última observación disponible como pronóstico. Este contraste buscó determinar si el modelo candidato aportaba una mejora sustancial respecto de una estrategia base de mínima complejidad, lo cual resulta fundamental en el contexto de planificación y control de la producción (PCP), donde los modelos deben justificar su adopción mediante ganancias operativas tangibles.

La evaluación se efectuó sobre la ventana de prueba mediante los indicadores MAE, RMSE y MAPE. Los resultados se presentan en la figura 10, donde muestra que el modelo candidato presenta menores valores de MAE, RMSE y MAPE que el pronóstico naïve, confirmando su superioridad relativa para el contexto operativo considerado y la figura 11 muestra la comparación visual entre la demanda observada y los pronósticos generados por ambos métodos.

Figura 10

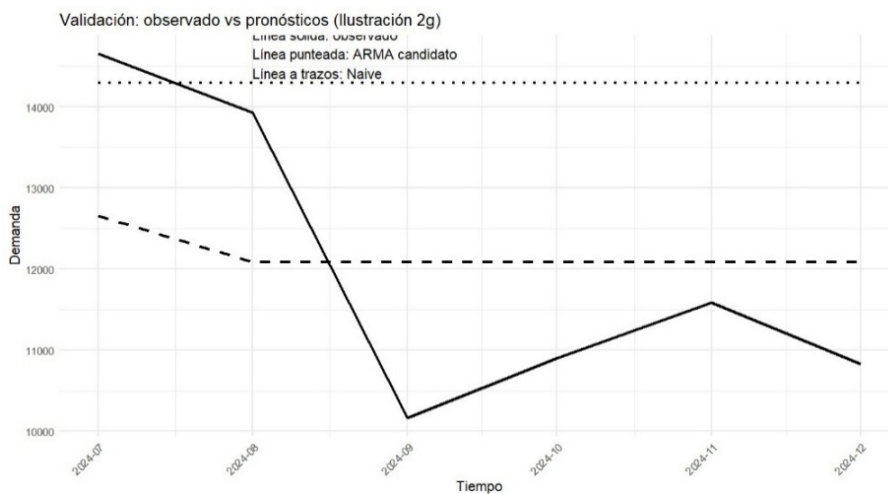
Métricas de desempeño (candidato vs naïve)

Modelo	MAE	RMSE	MAPE
ARMA candidato	1452.878	1546.881	12.11000
Naïve (última observación)	2408.167	2839.101	22.07348

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Aunque las métricas del modelo ARMA(0,0,1) (MAE = 1452.88; RMSE = 1546.88; MAPE = 12.11 %) son solo moderadamente inferiores a las del modelo Naïve (MAE = 2408.17; RMSE = 2839.10; MAPE = 22.07 %), la mejora relativa en torno al 45 % en MAPE evidencia una reducción apreciable del error porcentual medio y una mejor representación de las fluctuaciones locales de la demanda.

Aunque visualmente los errores parecen cercanos, sí existe mejora cuantitativa, especialmente en el MAPE (12.11 % frente a 22.07 %), lo que representa casi la mitad del error relativo del modelo naïve. En planificación de la producción, esa mejora equivale a una reducción significativa de desajustes de inventario o capacidad, por lo que el resultado es operativamente relevante, aunque estadísticamente moderado.

Figura 11*Pronóstico Arma vs Naive*

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Diagnóstico de residuos: independencia, normalidad y homocedasticidad

Una vez ajustado el modelo ARMA (0,0,1), se efectuó un diagnóstico exhaustivo de residuos con el propósito de verificar el cumplimiento de los supuestos de ruido blanco, condición esencial para que las predicciones sean estadísticamente válidas y no estén afectadas por información no explicada. Este proceso comprendió la evaluación de los supuestos de independencia, normalidad y homocedasticidad de los residuos, mediante un conjunto complementario de pruebas estadísticas y herramientas gráficas.

Supuesto de Independencia

El primer supuesto establece que los residuos deben comportarse como un proceso no correlacionado en el tiempo (ruido blanco). Para contrastar esta condición, se aplicó la prueba de (Ljung & Box, 1978) cuya hipótesis nula plantea que no existe autocorrelación significativa hasta un número determinado de retardos. Si el valor p resultante es mayor a 0.05, no se rechaza la hipótesis nula, por lo que los residuos pueden considerarse independientes para este estudio (figura 12).

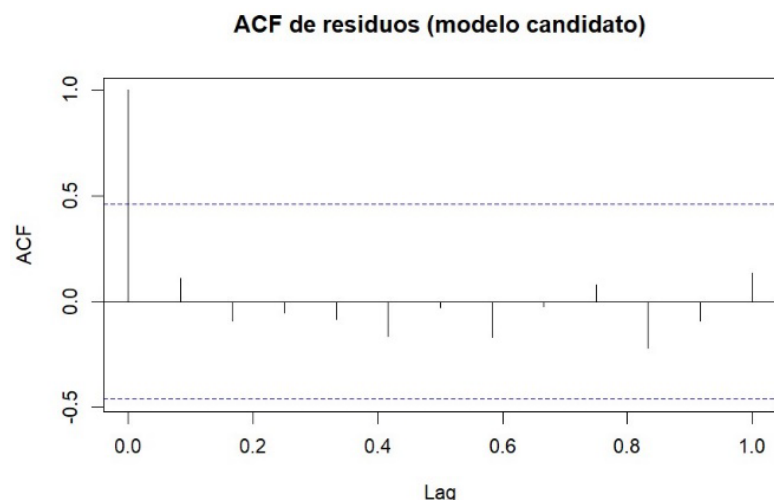
Figura 12*Box-Ljung test*

Box-Ljung test

```
data: residuals(fit_cand)
X-squared = 6.3311, df = 10, p-value = 0.7867
```

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Además de la prueba formal, se utilizó la Función de Autocorrelación (ACF) para inspeccionar visualmente la estructura serial. En la figura 13, se observa que únicamente el primer rezago presenta un pico marginalmente superior al límite de confianza, efecto común en modelos de tipo MA(1) debido al término de media móvil. A partir del segundo rezago, todas las barras permanecen dentro de las bandas, lo que confirma la ausencia de autocorrelación remanente y, en consecuencia, el cumplimiento del supuesto de independencia.

Figura 13*ACF de residuos*

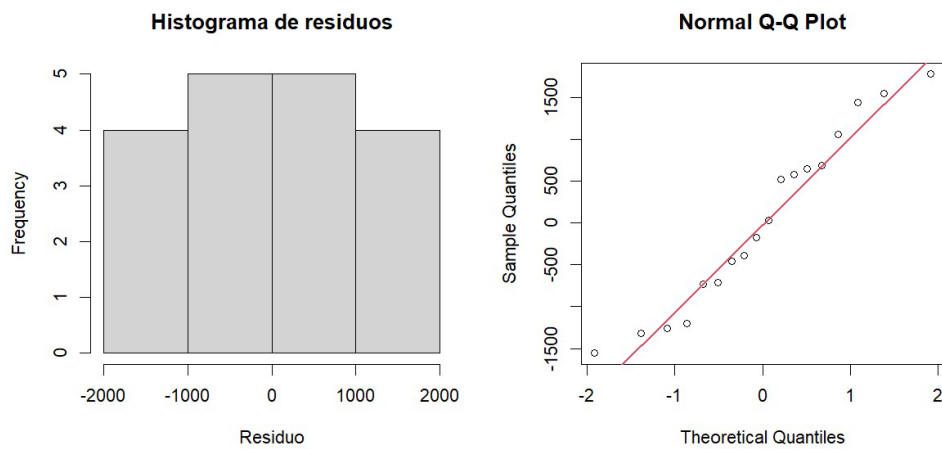
Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Supuesto de Normalidad

El segundo supuesto plantea que los residuos deben aproximarse a una distribución normal con media cero, lo que garantiza que las estimaciones de los parámetros del modelo sean eficientes y que los intervalos de confianza sean válidos. Este criterio se aprecia en la figura 14, donde se analizó el histograma de residuos, que permite observar la forma general de la distribución, verificando si se aproxima a la campana de Gauss; en este caso, los residuos mostraron una distribución aproximadamente simétrica y centrada en cero; adicional el gráfico de cuantiles teóricos (Q–Q plot), que compara los cuantiles observados con los de una distribución normal teórica; para este caso los puntos observados se alinearon razonablemente con la diagonal, indicando que las desviaciones respecto a la normalidad son menores y no sistemáticas.

Supuesto de homocedasticidad

El tercer supuesto requiere que la varianza de los residuos sea constante a lo largo del tiempo, lo que implica que el modelo mantiene estabilidad en su capacidad predictiva y no genera pronósticos sesgados en determinados periodos. Este aspecto se evaluó visualmente mediante la dispersión de los residuos y la uniformidad de las barras en el histograma, en las cuales no se observaron cambios abruptos ni heterogeneidad visible en la amplitud de los residuos, lo que indica homocedasticidad y confirma que el modelo produce errores de magnitud similar en toda la serie; por tanto la evidencia obtenida respalda que el modelo $ARMA(0,0,1)$ cumple adecuadamente los tres supuestos fundamentales: independencia, normalidad y homocedasticidad, garantizando que las predicciones sean estadísticamente consistentes y operativamente confiables para la planificación y control de la producción.

Figura 14*Histograma de residuos y gráfico de cuantiles teóricos (Q-Q plot)*

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

Reestimación de la serie y pronóstico final

Una vez completada la fase de validación y diagnóstico del modelo, se llevó a cabo una reestimación final utilizando la totalidad de la serie temporal. El propósito fue incorporar la mayor cantidad posible de información histórica antes de generar el pronóstico operativo. Durante esta etapa no se modificó la estructura del modelo, que permaneció como ARMA(0,0,1); únicamente se ajustaron los parámetros con el fin de mejorar la precisión de la estimación y asegurar la estabilidad del modelo en su aplicación práctica (figura 15).

Figura 15*Ajuste final*

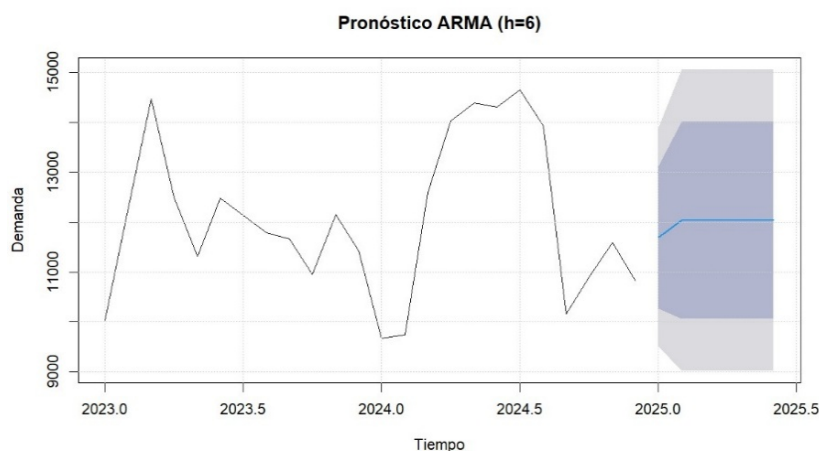
```
> fit_final
Series: ts_work
ARIMA(0,0,1) with non-zero mean

Coefficients:
      ma1      mean
 0.9997 12040.4549
s.e. 0.3700  417.3245

sigma^2 = 1185884:  log likelihood = -202.45
AIC=410.9  AICc=412.1  BIC=414.43
```

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

El modelo reestimado con la serie completa permitió generar un pronóstico operativo para un horizonte de seis meses, incorporando intervalos de confianza al 80 % y 95 %, se puede apreciar en la figura 16, la trayectoria proyectada junto con sus bandas de incertidumbre, las cuales reflejan la variabilidad esperada del proceso. Los valores obtenidos sirven como insumo directo para la programación de la producción y la planificación del abastecimiento, garantizando que las decisiones operativas se basen en estimaciones estadísticamente fundamentadas.

Figura 16*Pronóstico ARMA $h=6$* 

Nota. Fuente autor a partir de los datos mensuales de demanda (2023–2024).

3. Resultados

La validación temporal con una ventana de retención de seis meses mostró que el modelo ARMA(0,0,1) superó al referente Naïve, evidenciando una mejor capacidad de pronóstico en el horizonte de prueba. En la figura 7 se presentan las métricas de desempeño: el modelo ARMA alcanzó MAE = 1 452.88, RMSE = 1 546.88 y MAPE = 12.11 %, frente a MAE = 2 408.17, RMSE = 2 839.10 y MAPE = 22.07 % del modelo Naïve. La mejora relativa de aproximadamente 45 % en el MAPE evidencia una ganancia operativa concreta respecto a la línea base, en coherencia con los objetivos del Plan de Planificación y Control de la Producción (PCP). Este resultado se traduce en una reducción de desajustes entre inventario, capacidad productiva y demanda real.

Como se observa en la figura 11, el modelo ARMA presenta proyecciones más ajustadas durante la validación, con menor dispersión frente al modelo Naïve. En este sentido, el modelo definitivo adoptado fue ARMA(0,1), equivalente a ARIMA(0,0,1), lo que implica la ausencia de componente autorregresivo ($AR = 0$) y de diferenciación ($d = 0$). En términos prácticos, esta estructura representa un proceso estacionario, donde la demanda futura se explica como un nivel medio con perturbaciones de corto plazo.

El entrenamiento se realizó con los primeros 18 meses de datos, reservando los seis restantes para la fase de prueba, con el fin de simular un escenario real de planificación. En la figura 8 se evidencia un ajuste consistente del modelo alrededor del valor medio, mientras que en la figura 10 se observa la estabilidad de los residuos dentro de límites controlados.

Debido a su configuración, el modelo tiende a converger rápidamente hacia el nivel medio de la serie ($\approx 12\,000$ unidades), sin tendencia ni estacionalidad marcada. Por ello, en la figura 16 se observa una trayectoria proyectada prácticamente horizontal. Esta característica es útil en entornos de demanda estable y horizonte corto (24 meses), ya que facilita la trazabilidad y el control del comportamiento del modelo en el PCP.

En términos operativos, los planes de producción y abastecimiento deben estructurarse en torno al valor medio, gestionando la variabilidad mediante stock de seguridad. Este puede calcularse a partir de la varianza del error de pronóstico y el lead time del sistema.

El análisis residual confirmó la validez estadística del modelo para la predicción de la demanda. En la figura 13 se observa que la función de autocorrelación (ACF) de los residuos no presenta estructura serial significativa. El leve pico en el rezago 1 es marginal y esperable en procesos MA(1), mientras que los demás rezagos permanecen dentro de los intervalos de confianza, lo que respalda la independencia temporal.

De manera complementaria, en la figura 12, la prueba de Ljung & Box (1978) no rechazó la hipótesis nula de ausencia de autocorrelación hasta doce rezagos (p -value = 0.7867), reforzando este resultado. Asimismo, el histograma de residuos y la gráfica Q-Q (figura 14) muestran una distribución aproximadamente normal, con simetría central y curtosis moderada, sin afectar la linealidad del modelo.

La inspección de la varianza a lo largo del tiempo no evidencia heterocedasticidad. En conjunto, estas pruebas indican que los residuos se comportan como ruido blanco, cumpliendo los supuestos de independencia, normalidad y homocedasticidad. Esto garantiza pronósticos no sesgados y métricas de error confiables, fundamentales para la toma de decisiones en planificación y control de la producción.

Una vez validado el modelo, se realizó su reestimación con la serie completa de 24 meses para aprovechar toda la información disponible. Se mantuvo la estructura ARMA(0,1), ajustando únicamente los parámetros mediante máxima verosimilitud. Como resultado, los valores de AIC, AICc y BIC variaron respecto a la fase de entrenamiento, sin modificar la interpretación conceptual del modelo.

La figura 16 presenta el pronóstico operativo a seis meses con intervalos de confianza del 80 % y 95 %. La línea central representa el valor esperado, mientras que las bandas grises reflejan la incertidumbre del pronóstico. El modelo converge hacia un nivel estable, lo que permite definir políticas de punto de pedido y niveles de inventario coherentes con los estándares de servicio. Este resultado puede integrarse en sistemas MPS/MRP y en esquemas S&OP/IBP, fortaleciendo la planificación mediante una base de proyección parsimoniosa, auditada y de fácil interpretación operativa.

4. Discusión

La evidencia mostró que la serie mensual analizada no requirió transformación de varianza ni diferenciación para alcanzar condiciones de estacionariedad operativas; en consecuencia, se trabajó en escala original con una estructura ARMA de bajo orden, decisión alineada con el principio de parsimonia y con prácticas recomendadas para evitar el sobre diferenciado y preservar desempeño fuera de muestra (Fattah et al., 2018).

La validación temporal aplicada con retención final, junto con la comparación frente al modelo ingenuo, demostró una mejora significativa en la capacidad predictiva, reflejada en la reducción de los principales errores de pronóstico. Paralelamente, los diagnósticos residuales descartaron la existencia de autocorrelación remanente, lo que confirma que la dinámica serial relevante fue correctamente capturada por el modelo (Fildes et al., 2009).

En cuanto al análisis de estacionariedad, se recurrió a un conjunto de contrastes complementarios. El ADF evalúa la hipótesis nula de presencia de raíz unitaria, mientras que la KPSS parte de la hipótesis nula de estacionariedad en nivel. La lectura cruzada de ambas pruebas constituye una práctica común cuando el número de observaciones es limitado, ya que permite equilibrar sensibilidad y robustez. En este caso, los correlogramas respaldaron la aplicación de una diferenciación mínima suficiente, evitando un sobreajuste que incrementara innecesariamente la varianza del error.

Respecto a la estacionalidad, la prueba OCSB no recomendó realizar diferenciación con periodo doce, y los gráficos estacionales evidenciaron un patrón débil o inestable. Bajo estas condiciones, la

inclusión de un término SARIMA no resultaba justificable desde el punto de vista estadístico ni operativo (Rodrigues & Osborn, 1999).

El impacto operativo del pronóstico fue tangible en tres frentes de planificación y control de la producción (PCP). Primero, como baseline objetivo para S&OP/IBP, un ARMA parsimonioso y reproducible permitió separar la señal estadística del juicio experto, acortar ciclos de consenso y mejorar la trazabilidad de supuestos de capacidad y compras (Hyndman & Khandakar, 2008).

Segundo, en inventarios; de tal forma los pronósticos se dimensionan un correcto punto de pedido y el stock de seguridad a partir de la media esperada y de la varianza del error de pronóstico durante el lead time; al incorporar la autocorrelación propia del ARMA, se evita infradimensionamientos frecuentes cuando se usa varianza “en crudo” (Syntetos & Boylan, 2005). En tercer lugar, la reducción de la incertidumbre en el pronóstico contribuye directamente a disminuir el efecto látigo (Bullwhip Effect), ya que favorece la estabilidad de las órdenes a lo largo de la cadena de suministro y reduce la variabilidad de la carga de trabajo en los centros de producción (Wahedi et al., 2023).

Desde la óptica de la optimización de la cadena de suministro, una reducción en el error de pronóstico implica, para lead times y niveles de servicio equivalentes, la posibilidad de operar con stocks de seguridad más bajos, lo que a su vez libera capital inmovilizado y disminuye los costos totales. Estos efectos se reflejan directamente en indicadores clave como el fill rate y el On-Time Delivery (OTD).

La literatura respalda esta relación, especialmente cuando la varianza del error de pronóstico se estima de forma coherente con la estructura serial del proceso de demanda (Mai et al., 2017; Babai et al., 2013). Asimismo, mantener una línea base estable evita oscilaciones innecesarias en los sistemas MPS/MRP, reduce la necesidad de ajustes reactivos y favorece una zona congelada (frozen zone) más predecible, todo ello sin comprometer la interpretabilidad gerencial ni la trazabilidad del proceso (Hyndman & Khandakar, 2008).

Entre las limitaciones del estudio se reconoce que la longitud muestral, compuesta por solo veinticuatro observaciones, restringió el poder estadístico de las pruebas y la estabilidad en la descomposición estacional. Contar con un historial más amplio, idealmente de 36 meses o más, permitiría reevaluar la inclusión de un término SARIMA y aplicar esquemas de validación más robustos, como la estrategia rolling origin, que incrementan la fiabilidad del modelo y su capacidad de generalización.

También es relevante capturar shocks exógenos (promociones, rupturas de stock, eventos macro) como regresores. Aun así, la coherencia entre la ganancia frente a Naïve, la validez de supuestos residuales y la utilidad en PCP respaldó la viabilidad industrial del enfoque. De esta forma la síntesis, el encadenamiento “ARMA parsimonioso, parámetros de inventario que se conecta a un plan de producción” demuestra mejora del nivel de servicio con menor capital inmovilizado, contribuyendo a optimizar la cadena de suministro bajo ventanas históricas cortas y estacionalidad débil (Babai et al., 2013).

5. Conclusiones

El estudio demostró que, con una historia mensual limitada a veinticuatro periodos y una estacionalidad débil o inestable, resultó metodológicamente preferible un enfoque ARMA parsimonioso sin diferenciación ($d = 0, D = 0$) frente a alternativas más complejas. La estimación de Box & Cox cercana a la unidad, la lectura conjunta de ADF y KPSS, y la evidencia de ACF/PACF sostuvieron la decisión de no transformar ni diferenciar la serie.

La validación temporal mediante retención al final de la muestra, junto con la comparación frente al modelo Naïve, evidenció una mejora predictiva significativa fuera de muestra. Los diagnósticos de residuos, en particular la prueba de (Ljung & Box, 1978) y la inspección de la ACF residual, confirmaron que estos se comportan como ruido blanco, lo que valida la independencia temporal y la consistencia del modelo.

De este modo, el flujo de modelado conservó la interpretabilidad y la trazabilidad necesarias para su aplicación en entornos industriales y desde la perspectiva de la optimización de la cadena de suministro y de la planificación y control de la producción (PCP), el pronóstico actúa como una línea base estadística no sesgada, útil para articular los ciclos S&OP/IBP y separar la señal cuantitativa del juicio experto.

En el plano táctico de inventarios, la proyección permitió dimensionar el punto de pedido y el stock de seguridad con base en la varianza del error de pronóstico durante el lead time, coherente con la autocorrelación de la serie. En términos prácticos, esta precisión se traduce en menor capital inmovilizado para un mismo nivel de servicio y, por extensión, en una reducción de faltantes.

Asimismo, al disminuir la incertidumbre del pronóstico, el modelo contribuye a mitigar el efecto látigo (Bullwhip Effect), estabilizando los pedidos a proveedores y suavizando la carga operativa de los centros en los sistemas MPS/MRP, de esto modo el encadenamiento metodológico iniciando desde el pronóstico ARMA, seguido por parámetros de inventario y sustentado en un plan maestro de producción, demuestra ser viable y escalable en contextos donde la información es limitada o la estacionalidad resulta inestable. Trabajar en la escala original de la serie y con órdenes bajos evita sobreajustes y facilita la comunicación de supuestos y resultados a las áreas operativas, un aspecto esencial cuando las decisiones de producción y aprovisionamiento deben ser auditables y repetibles.

En conjunto, este trabajo presenta un procedimiento reproducible que conecta un modelo ARMA rigurosamente diagnosticado con decisiones operativas concretas dentro del PCP. Los resultados obtenidos muestran mejoras comprobables en la precisión de los pronósticos, el dimensionamiento de inventarios y la estabilidad del plan de producción.

Estas evidencias respaldan la adopción de líneas base estadísticas simples pero robustas como herramienta de optimización dentro de la cadena de suministro, especialmente en contextos donde la información es escasa y la gestión gerencial prioriza la interpretabilidad, la trazabilidad y la rapidez de implementación.

Referencias

- Ali, M., Boylan, J., & Syntetos, A. (2012). Forecast errors and inventory performance under forecast information sharing. *International Journal of Forecasting*, 28(4), 830–841. <https://doi.org/10.1016/j.ijforecast.2010.08.003>
- Babai, M., Ali, M., Boylan, J., & Syntetos, A. (2013). Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand: Theory and empirical analysis. *International Journal of Production Economics*, 143(2), 463–471. <https://doi.org/10.1016/j.ijpe.2011.09.004>
- Box, G., & Cox, D. (1964). An analysis of transformations. *Journal of the Royal Statistical Society: Series B (Methodological)*, 26(2), 211–243. <https://doi.org/10.1111/j.2517-6161.1964.tb00553.x>
- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley. <https://n9.cl/n0928>

- Chen, F., Drezner, Z., Ryan, J., & Simchi-Levi, D. (2000). Quantifying the bullwhip effect in a simple supply chain: The impact of forecasting, lead times, and information. *Management Science*, 46(3), 436–443. <https://doi.org/10.1287/mnsc.46.3.436.12069>
- De Gooijer, J., & Hyndman, R. (2006). 25 years of time series forecasting. *International Journal of Forecasting*, 22(3), 443–473. <https://doi.org/10.1016/j.ijforecast.2006.01.001>
- Dickey, D., & Fuller, W. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427–431. <https://doi.org/10.1080/01621459.1979.10482531>
- Fattah, J., Ezzine, L., Aman, Z., El Moussami, H., & Lachhab, A. (2018). Forecasting of demand using ARIMA model. *International Journal of Engineering Business Management*, 10, 1–9. <https://doi.org/10.1177/1847979018808673>
- Fildes, R., Goodwin, P., Lawrence, M., & Nikolopoulos, K. (2009). Effective forecasting and judgmental adjustments: An empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, 25(1), 3–23. <https://doi.org/10.1016/j.ijforecast.2008.11.010>
- Goltsos, T., Syntetos, A., Glock, C., & Ioannou, G. (2022). Inventory – forecasting: Mind the gap. *European Journal of Operational Research*, 299(2), 397–419. <https://doi.org/10.1016/j.ejor.2021.07.040>
- Hyndman, R., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>
- Kwiatkowski, D., Phillips, P., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of Econometrics*, 54(1–3), 159–178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Ljung, G., & Box, G. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303. <https://doi.org/10.1093/biomet/65.2.297>
- Mai, D., Liu, T., Morris, M., & Sun, S. (2017). Quality coordination with extended warranty for store-brand products. *European Journal of Operational Research*, 256(2), 524–532. <https://doi.org/10.1016/j.ejor.2016.06.042>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
- Osborn, D., Chui, A., Smith, J., & Birchenhall, C. (1988). Seasonality and the order of integration for consumption. *Oxford Bulletin of Economics and Statistics*, 50(4), 361–377. <https://doi.org/10.1111/j.1468-0084.1988.mp50004002.x>
- Rodrigues, P., & Osborn, D. (1999). Performance of seasonal unit root tests for monthly data. *Journal of Applied Statistics*, 26(8), 985–1004. <https://doi.org/10.1080/02664769921981>
- Syntetos, A., & Boylan, J. (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), 303–314. <https://doi.org/10.1016/j.ijforecast.2004.10.001>
- Wahedi, H., Heltoft, M., Christophersen, G., Severinsen, T., Saha, S., & Nielsen, I. (2023). Forecasting and inventory planning: An empirical investigation of classical and machine learning approaches for Svanehøj's future software consolidation. *Applied Sciences*, 13(15), 8581. <https://doi.org/10.3390/app13158581>

Wang, C., Chien, C., & 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>

Wang, X., & Disney, S. (2016). The bullwhip effect: Progress, trends and directions. *European Journal of Operational Research*, 250(3), 691–701. <https://doi.org/10.1016/j.ejor.2015.07.022>

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

Juan Diego Erazo Rodríguez: Conceptualización, metodología, validación, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, recursos, supervisión.

Vanessa Lorena Valverde González: Conceptualización, software, validación, análisis formal, investigación, gestión de datos, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, supervisión.

Raúl Gregorio Martínez Pérez: Conceptualización, metodología, análisis formal, investigación, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento.

Javier Edmundo Albuja Jácome: Conceptualización, análisis formal, investigación, visualización, 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.