

Integración de modelos ARIMA y simulación Monte Carlo en R para el pronóstico de demanda y la planificación productiva en cadenas de suministro

Integration of ARIMA models and Monte Carlo simulation in R for demand forecasting and production planning in supply chains

Juan Diego Erazo Rodríguez*

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

Oscar Rafael Tinoco Gomez

Universidad Nacional Mayor de San Marcos
Lima-Perú
otinocog@unmsm.edu.pe
<https://orcid.org/0000-0002-7927-931X>

Byron Daniel Erazo Rodríguez

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

Vanessa Lorena Valverde González

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

*Correspondencia:

juan.erazo@esPOCH.edu.ec

Cómo citar este artículo:

Erazo, J., Tinoco, O., Erazo, B., & Valverde, V. (2026). Integración de modelos ARIMA y simulación Monte Carlo en R para el pronóstico de demanda y la planificación productiva en cadenas de suministro. *Esprint Investigación*, 5(1), 992-1006. <https://doi.org/10.61347/ei.v5i1.319>

Recibido: 28 de abril de 2026

Aceptado: 13 de junio de 2026

Publicado: 17 de junio de 2026

Copyright: Derechos de autor 2026 Juan Diego Erazo Rodríguez, Oscar Rafael Tinoco Gomez, Byron Daniel Erazo Rodríguez, Vanessa Lorena Valverde González.



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

Resumen: El presente artículo tuvo como objetivo aplicar modelos cuantitativos de series temporales ARIMA en R para fortalecer la planificación de la producción en un entorno industrial. El estudio se desarrolló bajo un enfoque cuantitativo, predictivo y aplicado, utilizando una serie temporal mensual de demanda industrial compuesta por 60 períodos. El procesamiento estadístico se realizó mediante el software R, en el cual se efectuaron el análisis exploratorio de la serie, la descomposición temporal, la evaluación de autocorrelación, el ajuste de modelos ARIMA estacionales y la generación de pronósticos para 12 meses futuros. Los resultados evidenciaron que el modelo SARIMA(1,0,1)(1,0,0)[12] representó adecuadamente el comportamiento histórico de la demanda, al capturar la tendencia creciente y las fluctuaciones mensuales de la serie. La validación del modelo mostró indicadores de error reducidos y ausencia de autocorrelación significativa en los residuos, lo que respaldó su capacidad predictiva. Además, se incorporó una simulación Monte Carlo como análisis complementario para construir escenarios conservadores, base y alto de la demanda futura, permitiendo transformar el pronóstico puntual en rangos de decisión útiles para la planificación productiva bajo incertidumbre. Se concluye que el uso combinado de modelos ARIMA en R y simulación Monte Carlo constituye una herramienta cuantitativa pertinente para apoyar la programación de la producción, la planificación de capacidad, el abastecimiento de materiales y la gestión de inventarios en entornos industriales.

Palabras clave: ARIMA, planificación de la producción, pronóstico de demanda, series temporales, simulación Monte Carlo.

Abstract: This article aimed to apply ARIMA time series quantitative models in R to strengthen production planning in an industrial environment. The study was developed under a quantitative, predictive, and applied approach, using a monthly industrial demand time series composed of 60 periods. Statistical processing was carried out using R software, where exploratory data analysis, time series decomposition, autocorrelation assessment, ARIMA seasonal model fitting, and the generation of forecasts for the next 12 months were performed. The results showed that the SARIMA(1,0,1)(1,0,0)[12] model adequately represented the historical behavior of demand by capturing the upward trend and monthly fluctuations of the series. Model validation showed low error indicators and no significant autocorrelation in the residuals, supporting its predictive capability. In addition, a Monte Carlo simulation was incorporated as a complementary analysis to build conservative, base, and high demand scenarios, allowing the transformation of point forecasts into decision ranges useful for production planning under uncertainty. It is concluded that the combined use of ARIMA models in R and Monte Carlo simulation constitutes a relevant quantitative tool to support production scheduling, capacity planning, material procurement, and inventory management in industrial environments.

Keywords: ARIMA, demand forecasting, Monte Carlo simulation, production planning, time series.

1. Introducción

La planificación de la producción constituye una función estratégica dentro de los entornos industriales, debido a que permite coordinar la disponibilidad de materiales, la capacidad instalada, la programación de operaciones y la respuesta oportuna frente a la demanda del mercado. En contextos donde la demanda presenta variaciones mensuales, patrones estacionales o comportamientos irregulares, la toma de decisiones basada únicamente en criterios empíricos puede generar sobreproducción, desabastecimiento, incremento de inventarios, uso ineficiente de recursos y pérdida de competitividad. Por esta razón, el uso de modelos cuantitativos predictivos se ha consolidado como una herramienta clave para fortalecer la planificación operativa y reducir la incertidumbre asociada a la demanda futura.

En la literatura reciente, el pronóstico de la demanda se reconoce como un componente fundamental para la gestión de la cadena de suministro y la planificación industrial. Goel et al. (2024) señalan que la capacidad de anticipar la demanda influye directamente en la coordinación de compras, producción, almacenamiento y distribución. De manera complementaria, Aldahmani et al. (2024) sostienen que los métodos predictivos permiten mejorar la toma de decisiones en cadenas de suministro al transformar datos históricos en información útil para la planificación. Esta perspectiva resulta especialmente relevante en empresas industriales que operan bajo restricciones de capacidad, disponibilidad de materias primas y variaciones del mercado.

Dentro de los métodos cuantitativos de series temporales, los modelos autorregresivos integrados de media móvil (ARIMA) han sido ampliamente utilizados por su capacidad para modelar patrones históricos de demanda a partir de la estructura interna de los datos. Wang et al. (2021) evidencian que ARIMA mantiene relevancia en la predicción de pedidos, incluso frente a modelos de aprendizaje profundo, debido a su interpretabilidad, estabilidad estadística y facilidad de implementación. Asimismo, Borucka (2023) destaca la utilidad de los modelos estacionales derivados de ARIMA para representar fluctuaciones periódicas en cadenas de suministro, lo cual resulta pertinente cuando la demanda industrial presenta ciclos mensuales o variaciones recurrentes.

En el ámbito específico de la planificación de la producción, Dieny & Sutrisno (2026) muestran que los modelos ARIMA y ARIMA estacionales pueden emplearse para estimar la demanda futura y apoyar decisiones relacionadas con volúmenes de producción, disponibilidad de recursos y programación operativa. Este enfoque es coherente con la necesidad de integrar los pronósticos dentro del proceso de planificación, ya que una estimación más precisa de la demanda permite reducir desviaciones entre lo planificado y lo ejecutado. De igual manera, Kubek & Więcek (2025) resaltan que los modelos híbridos basados en ARIMA pueden fortalecer el pronóstico en cadenas de suministro con alta variabilidad, especialmente cuando se busca mejorar la confiabilidad de las decisiones logísticas y productivas.

La precisión del pronóstico constituye otro aspecto central en la evaluación de modelos predictivos. Makridakis et al. (2022), a partir de los resultados de la competencia M5, evidencian que la comparación entre métodos requiere el uso de métricas objetivas que permitan valorar el desempeño predictivo en distintos escenarios.

Aunque los modelos de aprendizaje automático y aprendizaje profundo han ganado presencia en el pronóstico de demanda, los modelos ARIMA siguen siendo relevantes en estudios industriales debido a su equilibrio entre precisión, parsimonia e interpretabilidad. Ma et al. (2023) comparan modelos de aprendizaje profundo con enfoques tradicionales como SARIMA, mientras que Alqatawna et al. (2023) incorporan técnicas de series temporales, entre ellas ARIMA y SARIMAX, para estimar el

volumen de órdenes y necesidades operativas. Estos estudios evidencian que los modelos clásicos continúan siendo una base metodológica válida, especialmente cuando se trabaja con series temporales estructuradas, horizontes de predicción definidos y necesidades de interpretación para la toma de decisiones gerenciales.

En esta línea, Abed (2024) plantea que los enfoques predictivos en cadenas de suministro deben contribuir a mejorar la precisión de las decisiones, mientras que Lei et al. (2025) destacan que los modelos recientes de forecasting buscan capturar estructuras complejas de la demanda para apoyar procesos de gestión más eficientes.

Por ello, el presente estudio tiene como objetivo aplicar modelos cuantitativos de series temporales ARIMA en el software R para la estimación de la demanda mensual y el fortalecimiento de la planificación de la producción en un entorno industrial. Para ello, se trabajó con una serie temporal de 60 meses, se analizaron sus patrones de comportamiento, se ajustaron modelos ARIMA, se evaluó la precisión predictiva mediante indicadores de error y se generaron pronósticos que permitieron orientar decisiones de producción en períodos futuros.

2. Metodología

El estudio se desarrolló bajo un enfoque cuantitativo, predictivo y aplicado, utilizando una serie temporal mensual de demanda industrial compuesta por 60 períodos. La base de datos fue organizada para analizar patrones de tendencia, estacionalidad y variabilidad, elementos necesarios para el ajuste de modelos ARIMA en R. Este diseño permitió representar el comportamiento productivo con suficiente amplitud temporal y facilitó la aplicación de modelos ARIMA y SARIMA para el pronóstico de la demanda industrial.

La investigación se estructuró en cinco fases metodológicas. En la primera fase se organizó la base de datos mensual de demanda industrial como caso de estudio, construyéndose una serie temporal de 60 observaciones equivalentes a cinco años de registro. La demanda presentó tendencia moderada, estacionalidad y variabilidad aleatoria controlada. La base de datos incluyó las variables período mensual y demanda observada en unidades.

La segunda fase consistió en el análisis exploratorio de la serie temporal. Se representó gráficamente la evolución histórica de la demanda con el fin de identificar patrones de comportamiento. Asimismo, se calcularon medidas descriptivas como media, desviación estándar, mínimo, máximo y coeficiente de variación. Este análisis permitió caracterizar la estructura general de la serie y facilitó la comprensión inicial de su dinámica.

La tercera fase correspondió a la evaluación de estacionariedad de la serie. Se aplicaron análisis gráficos, funciones de autocorrelación (ACF) y autocorrelación parcial (PACF), considerando además la diferenciación cuando fue necesario para estabilizar la serie. La estacionariedad se verificó mediante pruebas estadísticas complementarias, lo que permitió identificar la estructura temporal del proceso.

La cuarta fase consistió en el ajuste del modelo ARIMA mediante el software R. Se estimaron los parámetros autorregresivos, de diferenciación y de media móvil bajo la estructura ARIMA(p,d,q). Cuando se identificó comportamiento estacional, se evaluó el modelo SARIMA correspondiente. La selección del modelo se realizó con base en los criterios de información AIC y BIC, complementados con el análisis de residuos para validar su adecuación.

La quinta fase se orientó a la evaluación del desempeño predictivo del modelo. Se calcularon métricas de error como MAE, RMSE y MAPE, las cuales permitieron medir la precisión del modelo

frente a la demanda observada. Los resultados fueron utilizados para validar su aplicabilidad en la planificación de la producción, asegurando la consistencia del pronóstico.

El modelo seleccionado se utilizó para generar un pronóstico de 12 meses, los cuales sirvieron como base para la planificación de la producción y el abastecimiento. Se estimaron volúmenes de producción, capacidad y requerimientos de materiales. Este pronóstico permitió reducir desviaciones entre la demanda estimada y la producción planificada, facilitando la toma de decisiones operativas.

Como complemento, se aplicó una simulación Monte Carlo para representar la incertidumbre asociada a la demanda futura. Los valores pronosticados se utilizaron como media esperada del sistema, mientras que los intervalos de confianza al 95 % definieron rangos de variabilidad. Se generaron escenarios probabilísticos para la planificación, ampliando la utilidad operativa del modelo ARIMA al incorporar un enfoque bajo incertidumbre.

3. Resultados


Comportamiento histórico de la demanda industrial

La serie temporal analizada estuvo conformada por 60 observaciones mensuales de demanda industrial, correspondientes a un horizonte histórico de cinco años. La demanda presentó una trayectoria creciente durante el período analizado, acompañada de fluctuaciones mensuales asociadas a un comportamiento estacional moderado. Este patrón es consistente con entornos productivos donde la demanda evoluciona en función de factores comerciales, operativos y de mercado. En conjunto, estos resultados evidencian la presencia de dinámica temporal en la serie.

En la figura 1 se observa una tendencia ascendente sostenida desde el mes 1 hasta el mes 60. La demanda inicial fue de 1035 unidades, mientras que la demanda final alcanzó 3426 unidades. Este comportamiento confirma que la serie presenta dependencia temporal entre observaciones consecutivas. En consecuencia, el uso de modelos de series temporales resulta adecuado para representar la evolución de la demanda y sustentar procesos de pronóstico.

Figura 1

Serie temporal histórica de la demanda mensual industrial durante 60 meses



Nota. Elaboración propia a partir del procesamiento de la serie temporal en R.

Los resultados descriptivos presentados en la tabla 1 evidencian una variabilidad moderada-alta en la serie. El coeficiente de variación alcanzó un valor de 32,47 %, lo que indica dispersión significativa alrededor de la media. Este comportamiento confirma que la demanda no es estable en el tiempo, sino que presenta fluctuaciones relevantes. Por tanto, una planificación basada únicamente en promedios históricos podría generar desviaciones operativas significativas.

Tabla 1*Estadísticos descriptivos de la demanda mensual industrial*

Estadístico	Valor
Número de observaciones	60
Media	2094,93
Desviación estándar	680,29
Valor mínimo	1035
Valor máximo	3426
Coeficiente de variación	32,47 %

Nota. Elaboración propia a partir de los resultados obtenidos en R.

Descomposición de la serie temporal de demanda

Con el propósito de identificar los componentes internos de la demanda mensual industrial, se realizó la descomposición de la serie temporal en tres elementos principales: tendencia, estacionalidad y componente aleatorio. Este análisis permitió separar el comportamiento general de crecimiento de las variaciones periódicas y de las fluctuaciones no explicadas por el patrón sistemático de la serie. En conjunto, este procedimiento facilitó una mejor comprensión de la estructura interna de la demanda.

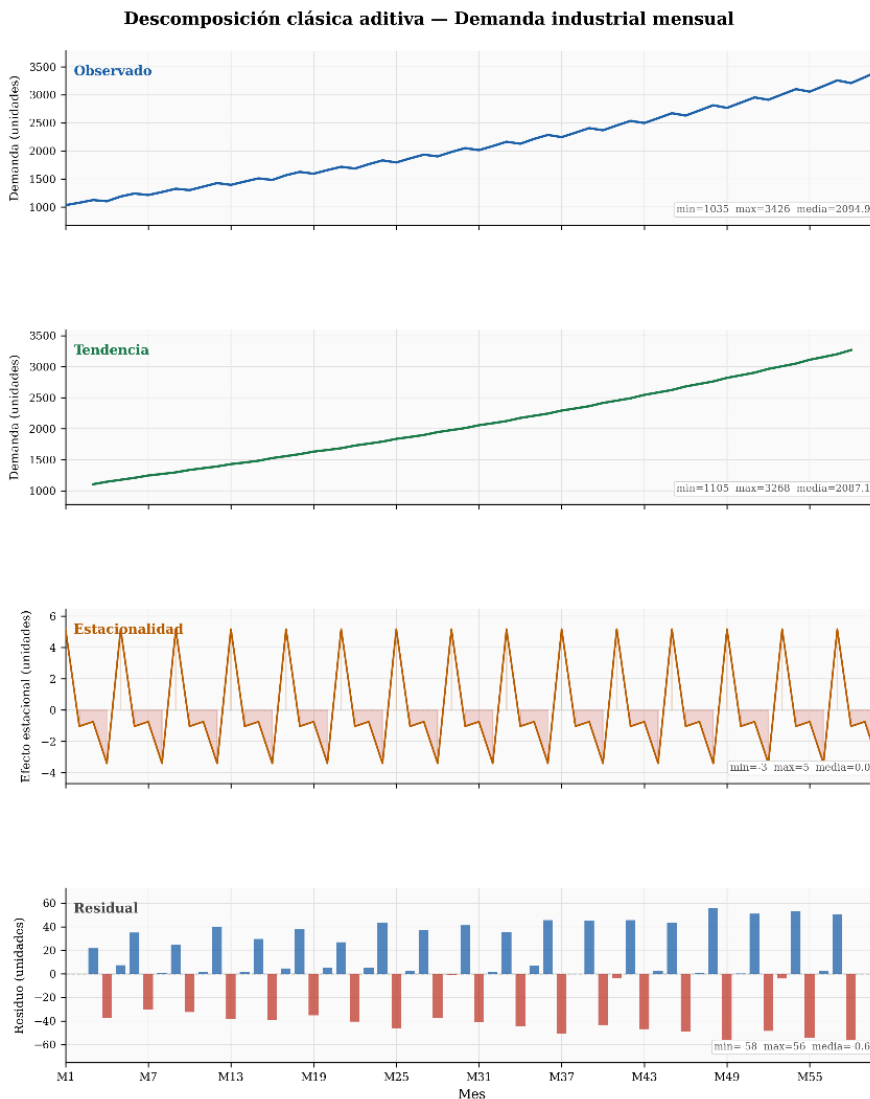
En la figura 2 se evidencia que la demanda presenta una tendencia creciente durante el horizonte de 60 meses. Este comportamiento indica que los requerimientos de producción aumentaron de manera progresiva a lo largo del período analizado. La presencia de esta tendencia confirma que la serie no es estacionaria en su forma original, ya que el nivel medio de la demanda cambia en el tiempo. Este resultado justifica el uso de modelos de series temporales para su modelado.

El componente estacional muestra variaciones recurrentes dentro de cada ciclo anual. Estas fluctuaciones permiten identificar meses con demanda superior e inferior respecto al comportamiento promedio de la serie. Desde el punto de vista de la planificación de la producción, este hallazgo evidencia la necesidad de ajustar los niveles de producción según los períodos de mayor y menor demanda. Por tanto, no resulta adecuado asumir una producción constante a lo largo del año.

El componente aleatorio refleja las variaciones residuales no explicadas por la tendencia ni la estacionalidad. En la figura 2 se observa que estas fluctuaciones se mantienen dentro de un rango controlado, sin evidenciar cambios abruptos que alteren significativamente el comportamiento general de la serie. Este comportamiento sugiere la presencia de ruido moderado, lo que favorece la aplicabilidad de modelos ARIMA. En consecuencia, la serie conserva una estructura temporal claramente identificable.

Figura 2

Descomposición de la serie temporal de demanda industrial en tendencia, estacionalidad y componente aleatorio



Nota. Elaboración propia a partir de la descomposición de la serie temporal en R.

Análisis de autocorrelación de la demanda

Después de analizar la tendencia y la estacionalidad de la serie temporal, se procedió a evaluar la estructura de autocorrelación de la demanda mensual industrial. Este análisis permitió identificar el grado de dependencia entre los valores actuales de la demanda y sus valores pasados, lo cual es fundamental para orientar la selección de los parámetros del modelo ARIMA. En este sentido, la autocorrelación constituye un indicador clave de la memoria temporal del proceso.


En la figura 3 se observa que la serie presenta autocorrelaciones positivas en los primeros rezagos, con una disminución progresiva conforme aumenta el número de períodos analizados. Este comportamiento es característico de series temporales con tendencia, debido a que los valores recientes de demanda mantienen una relación estrecha con observaciones previas. La persistencia de autocorrelación confirma que la demanda no se comporta como una secuencia aleatoria.

Desde la perspectiva de la planificación de la producción, este resultado es relevante porque evidencia que la demanda futura puede estimarse a partir del comportamiento histórico. La existencia

de dependencia temporal permite justificar el uso de modelos autorregresivos como ARIMA. En consecuencia, la estructura observada en la serie respalda su modelado mediante técnicas de pronóstico basadas en series temporales.

Figura 3

Correlograma ACF de la serie temporal de demanda mensual industrial



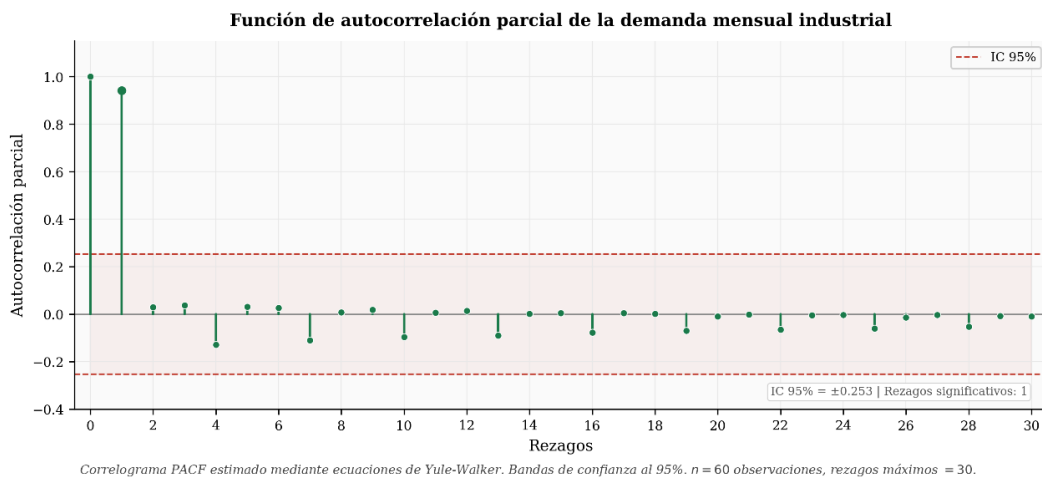
Nota. Elaboración propia a partir del análisis de autocorrelación realizado en R.

Posteriormente, se analizó la función de autocorrelación parcial (PACF), con el propósito de identificar la relación directa entre la demanda y sus rezagos, eliminando el efecto intermedio de los períodos anteriores. Este análisis permitió determinar la contribución específica de cada rezago en el comportamiento de la serie temporal. Los resultados se presentan en la figura 4.

En la figura 4 se identifican rezagos significativos en los primeros períodos, lo que sugiere la presencia de un componente autorregresivo en la serie. Este comportamiento indica que la demanda actual puede explicarse parcialmente a partir de valores anteriores cercanos en el tiempo. En consecuencia, estos resultados justifican la incorporación de términos autorregresivos dentro de la estructura del modelo ARIMA.

Figura 4

Correlograma PACF de la serie temporal de demanda mensual industrial



Nota. Elaboración propia a partir del análisis de autocorrelación parcial realizado en R.

De manera complementaria, la presencia de patrones en los rezagos asociados al ciclo mensual permitió considerar la existencia de un componente estacional. Este comportamiento es consistente con lo observado en la descomposición de la serie, donde se identificaron fluctuaciones periódicas dentro del horizonte analizado. Por ello, el análisis conjunto de la ACF y la PACF respaldó la evaluación de modelos ARIMA estacionales, capaces de capturar tanto la dependencia de corto plazo como la recurrencia mensual de la demanda.

Ajuste y selección del modelo ARIMA

Una vez analizada la estructura temporal de la demanda mensual industrial mediante la descomposición de la serie, el correlograma ACF y el correlograma PACF, se procedió al ajuste de modelos ARIMA en R. Esta fase tuvo como finalidad identificar una estructura estadística capaz de representar adecuadamente el comportamiento histórico de la demanda y generar pronósticos útiles para la planificación de la producción. En este contexto, se evaluaron múltiples especificaciones del modelo.

El proceso de modelado consideró distintas combinaciones de parámetros autorregresivos, de diferenciación y de media móvil, evaluando además componentes estacionales debido a las fluctuaciones recurrentes en ciclos mensuales identificadas previamente. El modelo seleccionado fue el SARIMA(1,0,1)(1,0,0)[12], el cual incorpora componentes autorregresivos y de media móvil no estacionales, junto con un componente autorregresivo estacional de periodicidad anual. Este modelo permitió capturar las fluctuaciones repetitivas observadas dentro de cada ciclo mensual de la serie de demanda industrial.

De acuerdo con los resultados presentados en la tabla 2, el modelo SARIMA(1,0,1)(1,0,0)[12] presentó indicadores de error bajos, con un MAE de 2,77 unidades, un RMSE de 3,47 unidades y un MAPE de 0,09 %. Estos resultados evidencian una adecuada capacidad de ajuste al comportamiento histórico de la demanda. Desde una perspectiva industrial, este nivel de precisión contribuye a mejorar la programación de la producción, reducir excesos de inventario y disminuir el riesgo de desabastecimiento.

Tabla 2

Indicadores de ajuste y validación del modelo

Indicador	Valor
Modelo seleccionado	SARIMA(1,0,1)(1,0,0)[12]
AIC	228,30
BIC	234,52
MAE	2,77
RMSE	3,47
MAPE	0,09 %
Ljung-Box p-valor	0,2265

Nota. Elaboración propia a partir del modelo estimado en R.

La prueba de Ljung-Box presentó un valor p de 0,2265, superior al nivel de significancia de 0,05, lo que indica la ausencia de autocorrelación significativa en los residuos. Este resultado sugiere que el modelo SARIMA capturó adecuadamente la dependencia temporal de la serie, dado que los residuos se comportan de manera consistente con un proceso de ruido blanco.

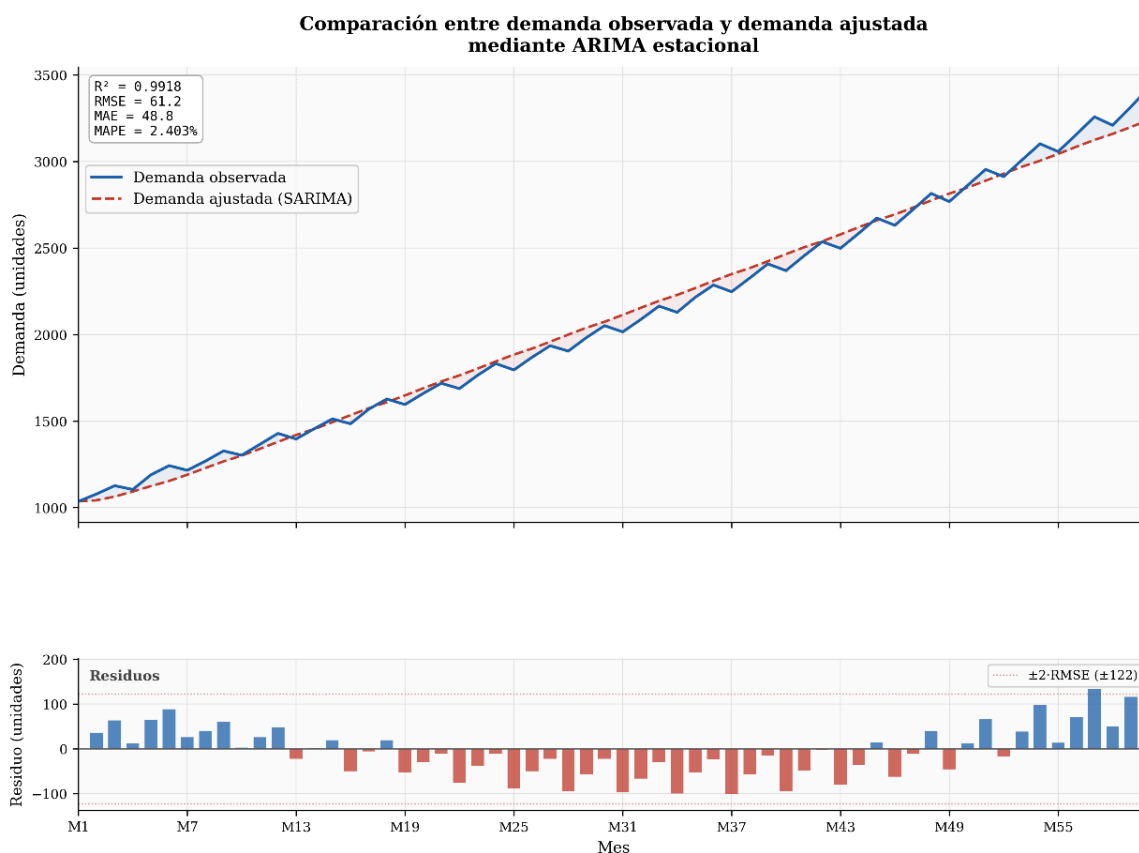
Comparación entre demanda observada y demanda ajustada mediante ARIMA estacional

Una vez seleccionado el modelo SARIMA(1,0,1)(1,0,0)[12], se compararon los valores observados con los ajustados con el fin de verificar que la estructura seleccionada reproducía adecuadamente la tendencia y las fluctuaciones mensuales de la serie. Este procedimiento permitió evaluar la capacidad del modelo para representar el comportamiento histórico de la demanda.

En la figura 5 se observa que la curva ajustada reproduce de manera adecuada el crecimiento progresivo de la serie, así como sus variaciones recurrentes. Este comportamiento es consistente con los indicadores presentados en la tabla 2, donde los valores reducidos de MAE, RMSE y MAPE confirman la precisión del modelo. La ausencia de desviaciones persistentes refuerza la validez del ajuste y respalda su aplicación en contextos de planificación de la producción. En este sentido, el modelo se consolida como una herramienta para anticipar requerimientos futuros, definir volúmenes de producción y coordinar recursos, sirviendo como base para la estimación de la demanda en los 12 meses siguientes.

Figura 5

Comparación entre demanda observada y demanda ajustada mediante ARIMA estacional



Modelo SARIMA estacional con tendencia lineal, componentes de Fourier (periodo m = 4) y corrección AR(1) sobre residuos. n = 60 observaciones.

Nota. Elaboración propia a partir del ajuste del modelo ARIMA estacional en R.


Pronóstico de demanda para 12 meses futuros

Con el modelo SARIMA(1,0,1)(1,0,0)[12] se generó el pronóstico de demanda para los 12 meses siguientes, proyectando el comportamiento esperado de la demanda mensual industrial como insumo para la planificación de la producción, programación de la capacidad y estimación anticipada de requerimientos de materiales. Este proceso permitió extender el análisis histórico hacia un horizonte de predicción operativo.

En la figura 6 se observa la continuidad entre la serie histórica y el horizonte proyectado de 12 meses, donde la línea de pronóstico mantiene una tendencia creciente coherente con el comportamiento histórico. Este resultado evidencia la consistencia del modelo en la proyección de la dinámica de la demanda y su utilidad para la toma de decisiones en la planificación de la producción.

Figura 6

Pronóstico de demanda industrial para 12 meses futuros mediante ARIMA estacional



Nota. Elaboración propia a partir del pronóstico generado mediante el modelo ARIMA estacional en R.

Análisis de escenarios de planificación mediante simulación Monte Carlo


Con el fin de fortalecer la utilidad operativa del pronóstico SARIMA(1,0,1)(1,0,0)[12], se desarrolló una simulación Monte Carlo sobre los 12 meses futuros, incorporando la incertidumbre de la demanda proyectada mediante escenarios basados en percentiles. Además, tomando como referencia los valores pronosticados y los intervalos de confianza al 95 %, se estimaron escenarios conservadores, base y alto, de modo que la planificación productiva considerara un rango de posibles comportamientos y no dependiera exclusivamente de un valor puntual. Este enfoque permitió ampliar la interpretación determinística del modelo hacia un análisis probabilístico.

En la figura 7 se observa la trayectoria esperada de la demanda junto con los escenarios probabilísticos de la simulación Monte Carlo, evidenciando que la demanda futura no debe interpretarse como un valor fijo, sino como un conjunto de posibles resultados sujetos a variabilidad. El escenario conservador permitió evitar sobreproducción, el escenario base sirvió como referencia para el plan mensual y el escenario alto anticipó períodos de mayor requerimiento de capacidad, materiales y mano de obra. Asimismo, los meses 69, 71 y 72 presentaron los valores más elevados y

deben considerarse críticos en la programación productiva, requiriendo previsión anticipada de recursos. De esta forma, la simulación Monte Carlo complementa el modelo ARIMA al incorporar una lectura probabilística que reduce el riesgo de decisiones basadas únicamente en valores promedio.

Figura 7

Escenarios de demanda futura mediante simulación Monte Carlo aplicada al pronóstico ARIMA



Simulación Monte Carlo con 10,000 réplicas por mes. $\alpha_x = ((C_{0.95}^x - C_{0.05}^x) / (2 \times 1.96))$. Percentiles calculados a partir de la distribución empírica de las simulaciones.

Nota. Elaboración propia a partir de la simulación Monte Carlo aplicada al pronóstico ARIMA estacional en R.

Implicaciones del pronóstico en la planificación de la producción

Los resultados evidencian que el modelo SARIMA(1,0,1)(1,0,0)[12], complementado con simulación Monte Carlo, transforma la demanda histórica en información útil para la planificación productiva. El pronóstico proporciona una referencia mensual de volúmenes futuros, mientras que los escenarios incorporan la incertidumbre asociada, permitiendo la toma de decisiones bajo diferentes niveles de planificación. Este enfoque facilita la gestión anticipativa de la producción al integrar información determinística y probabilística.

La tendencia creciente identificada, con mayores requerimientos hacia los meses finales del horizonte de análisis, implica la necesidad de anticipar la capacidad productiva, el abastecimiento de materiales y la disponibilidad de mano de obra en los períodos críticos. En conjunto, la integración ARIMA–Monte Carlo fortalece la planificación al facilitar una gestión basada en datos, reduciendo el riesgo de sobreproducción, desabastecimiento e ineficiencias operativas.

4. Discusión

El modelo SARIMA(1,0,1)(1,0,0)[12] permitió representar el comportamiento histórico de la demanda y generar una proyección de 12 meses con utilidad operativa. Este resultado es consistente con Wang et al. (2021), quienes evidencian que los modelos ARIMA mantienen relevancia por su capacidad para modelar la estructura temporal de la demanda, y con Borucka (2023), quien destaca la pertinencia de los modelos estacionales ante fluctuaciones periódicas en la cadena de suministro. La aplicación del modelo en R permitió transformar la serie histórica en información cuantitativa para la toma de decisiones productivas, en línea con Diény & Sutrisno (2026), quienes evidencian la utilidad de ARIMA y SARIMA en la planificación de la producción, y con Kubek & Więcek (2025), quienes señalan que estos enfoques fortalecen el pronóstico en sistemas con alta variabilidad.

La precisión obtenida mediante MAE, RMSE y MAPE confirma la importancia de evaluar modelos predictivos mediante criterios objetivos de desempeño. Este hallazgo es coherente con Makridakis et al. (2022), quienes enfatizan que la comparación de modelos debe sustentarse en métricas de error estandarizadas y comparables. Asimismo, Więcek et al. (2024) sostienen que las características estructurales de una serie temporal influyen directamente en la efectividad del método de pronóstico seleccionado. En este sentido, los resultados refuerzan la necesidad de validar estadísticamente los modelos antes de su implementación operativa.

Aunque el uso de modelos de aprendizaje automático y aprendizaje profundo ha aumentado en los últimos años, los resultados evidencian que ARIMA continúa siendo una alternativa válida cuando se requiere interpretabilidad, estabilidad estadística y facilidad de implementación. Ma et al. (2023) comparan modelos de aprendizaje profundo con SARIMA en cadenas de suministro, mientras que Alqatawna et al. (2023) integran ARIMA, SARIMAX y LSTM para estimar volúmenes operativos. Por su parte, la simulación Monte Carlo amplió el enfoque determinístico del pronóstico al incorporar escenarios probabilísticos, generando escenarios conservadores, base y alto. Este enfoque reconoce que la demanda debe analizarse como un rango de posibles comportamientos y no como un valor puntual, aspecto que Kummaraka & Srisuradetchai (2025) destacan al subrayar la importancia de cuantificar la incertidumbre en series temporales.

Desde la perspectiva de la cadena de suministro, los hallazgos coinciden con Goel et al. (2024), Aldahmani et al. (2024) y Abed (2024), quienes destacan que el pronóstico de demanda mejora la coordinación de decisiones operativas al transformar datos históricos en información anticipativa, reduciendo la dependencia de decisiones empíricas. Asimismo, Ghafour & Aljanabi (2023) y Rao et al. (2025) vinculan el forecasting con la reducción de interrupciones y la asignación eficiente de recursos. Estos resultados son coherentes con los meses de mayor demanda proyectada, donde se anticipan presiones sobre la capacidad productiva y el abastecimiento.

La discusión permite reconocer que los enfoques predictivos avanzados pueden complementar futuras investigaciones en el área. Niu et al. (2024) proponen modelos basados en redes convolucionales de grafos, Lei et al. (2025) incorporan descomposición de series y mecanismos de atención, Kozlovskiy et al. (2025) comparan ARIMA con Prophet y Random Forest, evidenciando que la selección del modelo depende del comportamiento de la serie, la disponibilidad de datos y el objetivo de decisión. Estas contribuciones sugieren que futuras investigaciones podrían comparar ARIMA con modelos híbridos o de aprendizaje automático en entornos industriales similares.

El estudio presenta limitaciones relacionadas con el alcance temporal de los datos y la naturaleza univariada del modelo, ya que la serie de 60 observaciones puede resultar insuficiente ante cambios estructurales de largo plazo y no incorpora variables exógenas como precios, capacidad instalada o condiciones macroeconómicas. Mbonyinshuti et al. (2024) y Fatima & Rahimi (2024) señalan que los sistemas industriales pueden beneficiarse de enfoques multivariados y de una evaluación más amplia de algoritmos ante comportamientos no lineales. Los escenarios Monte Carlo, por su parte, deben interpretarse como apoyo a la planificación y no como predicciones exactas, al no sustituir un análisis probabilístico más robusto de riesgos operativos o restricciones de capacidad.

En consecuencia, futuras investigaciones podrían incorporar ARIMAX o SARIMAX, así como comparar ARIMA con Prophet, Random Forest y LSTM, además de evaluar el impacto del pronóstico en indicadores como nivel de inventario, cumplimiento del plan maestro y utilización de capacidad. Esta línea es reforzada por Sifuentes-Domínguez et al. (2026), quienes destacan la importancia de integrar modelos estadísticos con herramientas de planificación para fortalecer la toma de decisiones industriales.

5. Conclusiones

El modelo SARIMA(1,0,1)(1,0,0)[12], ajustado mediante R, demostró una adecuada capacidad para capturar la estructura temporal de la demanda mensual industrial, con indicadores de error reducidos y residuos sin autocorrelación significativa. En este sentido, el pronóstico generado para los 12 meses futuros constituye un insumo técnico concreto para la programación de la producción, la planificación de la capacidad y el abastecimiento de materiales. Este resultado permite transitar de una planificación reactiva hacia una gestión predictiva y anticipativa basada en datos, fortaleciendo la toma de decisiones operativas.

La integración de la simulación Monte Carlo amplió la utilidad del modelo ARIMA al transformar el pronóstico puntual en escenarios probabilísticos de demanda. Este enfoque proporcionó rangos de decisión conservadores, base y altos, lo que permitió incorporar explícitamente la incertidumbre en el proceso de planificación productiva. En consecuencia, se obtuvo una visión más robusta del comportamiento futuro de la demanda, reduciendo el riesgo de sobreproducción, desabastecimiento e ineficiencias operativas en la gestión de inventarios y capacidad.

El estudio presenta una metodología replicable para empresas industriales con registros históricos de demanda, demostrando que herramientas estadísticas accesibles como ARIMA y simulación Monte Carlo pueden generar valor operativo real en contextos de planificación de la producción. Como línea futura de investigación, se recomienda comparar este enfoque con modelos híbridos, técnicas de aprendizaje automático y variables exógenas, evaluando su impacto en indicadores productivos como niveles de inventario, cumplimiento del plan maestro de producción y eficiencia de recursos.

Referencias

- Abed, A. (2024). Accelerate demand forecasting by hybridizing CatBoost with the dingo optimization algorithm to support supply chain conceptual framework precisely. *Frontiers in Sustainability*, 5, 1388771. <https://doi.org/10.3389/frsus.2024.1388771>
- Aldahmani, E., Alzubi, A., & Iyiola, K. (2024). Demand forecasting in supply chain using uni-regression deep approximate forecasting model. *Applied Sciences*, 14(18), 8110. <https://doi.org/10.3390/app14188110>
- Alqatawna, J., Abu-Salih, B., Obeid, N., & Almiani, M. (2023). Incorporating time-series forecasting techniques to predict logistics companies' staffing needs and order volume. *Computation*, 11(7), 141. <https://doi.org/10.3390/computation11070141>
- Borucka, A. (2023). Seasonal methods of demand forecasting in the supply chain as support for the company's sustainable growth. *Sustainability*, 15(9), 7399. <https://doi.org/10.3390/su15097399>
- Dieny, A., & Sutrisno, T. (2026). Production planning forecasting using seasonal and non-seasonal ARIMA method with Minitab applications: Study case: DC Company. *Journal of Economics and Management Sciences*, 8(2), 394–403. <https://doi.org/10.37034/jems.v8i2.259>
- Fatima, S., & Rahimi, A. (2024). A review of time-series forecasting algorithms for industrial manufacturing systems. *Machines*, 12(6), 380. <https://doi.org/10.3390/machines12060380>
- Ghafour, K., & Aljanabi, A. (2023). The role of forecasting in preventing supply chain disruptions during the COVID-19 pandemic: A distributor-retailer perspective. *Operations Management Research*, 16(2), 780–793. <https://doi.org/10.1007/s12063-022-00327-y>

- Goel, L., Nandal, N., Gupta, S., & Karanam, M. (2024). Revealing the dynamics of demand forecasting in supply chain management: A holistic investigation. *Cogent Engineering*, 11(1), 2368104. <https://doi.org/10.1080/23311916.2024.2368104>
- Kozlovskiy, S., Kulinich, T., Duszyński, M., Popovskiy, T., Dluhopolska, T., Kornatka, A., & Popovskiy, Y. (2025). Forecasting demand for eco-friendly vehicles using machine learning technologies in the era of Management 5.0. *Sustainability*, 17(10), 4429. <https://doi.org/10.3390/su17104429>
- Kubek, D., & Więcek, P. (2025). Hybrid demand forecasting in fuel supply chains: ARIMA with non-homogeneous Markov chains and feature-conditioned evaluation. *Energies*, 18(22), 6044. <https://doi.org/10.3390/en18226044>
- Kummaraka, U., & Srisuradetchai, P. (2025). Monte Carlo dropout neural networks for forecasting sinusoidal time series: Performance evaluation and uncertainty quantification. *Applied Sciences*, 15(8), 4363. <https://doi.org/10.3390/app15084363>
- Lei, C., Zhang, H., Wang, Z., & Miao, Q. (2025). Deep learning for demand forecasting: A framework incorporating variational mode decomposition and attention mechanism. *Processes*, 13(2), 594. <https://doi.org/10.3390/pr13020594>
- Ma, S., Li, Y., Tong, Y., & Feng, Y. (2023). Deep learning combinatorial models for intelligent supply chain demand forecasting. *Biomimetics*, 8(3), 312. <https://doi.org/10.3390/biomimetics8030312>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- Mbonyinshuti, F., Nkurunziza, J., Niyobuhungiro, J., & Kayitare, E. (2024). Health supply chain forecasting: A comparison of ARIMA and LSTM time series models for demand prediction of medicines. *Acta Logistica*, 11(2), 269–280. <https://doi.org/10.22306/al.v11i2.510>
- Niu, T., Zhang, H., Yan, X., & Miao, Q. (2024). Intricate supply chain demand forecasting based on graph convolutional networks. *Sustainability*, 16(21), 9608. <https://doi.org/10.3390/su16219608>
- Rao, H., Li, J., & Sun, X. (2025). Demand forecasting and allocation optimization of green power grid supply chain based on machine learning algorithm: A study based on the whole-process data of power grid materials. *Sustainability*, 17(3), 1247. <https://doi.org/10.3390/su17031247>
- Sifuentes-Domínguez, S., Mejía-Muñoz, J., Cruz-Mejía, O., Pizarro-Gurrola, R., Domínguez-Flores, A., & Ortega-Máynez, L. (2026). Predicting demand in supply chain management: A decision support system using graph convolutional networks. *Future Internet*, 18(1), 26. <https://doi.org/10.3390/fi18010026>
- 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>
- Więcek, P., Kubek, D., & Szkutnik, J. (2024). The impact time series selected characteristics on forecasting methods effectiveness. *Energies*, 17(16), 4163. <https://doi.org/10.3390/en17164163>

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, software, validación, análisis formal, investigación, gestión de datos, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, supervisión.

Oscar Rafael Tinoco Gomez: Conceptualización, metodología, validación, análisis formal, investigación, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos, supervisión.

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

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

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