



**UNIVERSIDAD TECNOLÓGICA
INDOAMÉRICA**

FACULTAD DE INGENIERÍAS

**MAESTRÍA EN INGENIERÍA INDUSTRIAL CON MENCIÓN EN LOGÍSTICA
Y CADENA DE SUMINISTRO**

TEMA:

**MODELACIÓN PREDICTIVA: ESQUEMA BASADO EN LA DEMANDA,
PRODUCCIÓN Y UNIDADES DEFECTUOSAS PARA LA
OPTIMIZACIÓN DEL SUMINISTRO Y PRODUCCIÓN**

Trabajo de Titulación previo a la obtención del título de Magister en Ingeniería Industrial con mención en Logística y Cadena de Suministro.

Autor

Ing. Llerena Poveda Carlos Enrique.

Tutora

Mgtr. Proaño Altamirano Gladys Elizabeth.

AMBATO– ECUADOR

2026

**AUTORIZACIÓN POR PARTE DEL AUTOR PARA LA CONSULTA,
REPRODUCCIÓN PARCIAL O TOTAL, Y PUBLICACIÓN ELECTRÓNICA
DEL TRABAJO DE TITULACIÓN**

Yo, Llerena Poveda Carlos Enrique, declaro ser autor del Trabajo de Titulación con el nombre “MODELACIÓN PREDICTIVA: ESQUEMA BASADO EN LA DEMANDA, PRODUCCIÓN Y UNIDADES DEFECTUOSAS PARA LA OPTIMIZACIÓN DEL SUMINISTRO Y PRODUCCIÓN”, como requisito para optar al grado de Magíster en Ingeniería Industrial con mención en Logística y Cadena de Suministro y autorizo al Sistema de Bibliotecas de la Universidad Indoamérica, para que con fines netamente académicos divulgue esta obra a través del Repositorio Digital Institucional (RDI-UTI).

Los usuarios del RDI-UTI podrán consultar el contenido de este trabajo en las redes de información del país y del exterior, con las cuales la Universidad tenga convenios. La Universidad Indoamérica no se hace responsable por el plagio o copia del contenido parcial o total de este trabajo.

Del mismo modo, acepto que los Derechos de Autor, Morales y Patrimoniales, sobre esta obra, serán compartidos entre mi persona y la Universidad Indoamérica, y que no tramitaré la publicación de esta obra en ningún otro medio, sin autorización expresa de la misma. En caso de que exista el potencial de generación de beneficios económicos o patentes, producto de este trabajo, acepto que se deberán firmar convenios específicos adicionales, donde se acuerden los términos de adjudicación de dichos beneficios.

Para constancia de esta autorización, en la ciudad de Ambato a los 28 días del mes de abril de 2026, firmo conforme:

Autor: Ing. Llerena Poveda Carlos Enrique

Firma:

Número de Cédula: 1803537826

Dirección: Tungurahua, Ambato, La Matriz, Los Sauces.

Correo Electrónico: carlosufo22@gmail.com

Teléfono: 0987016756

APROBACIÓN DE LA DIRECTORA

En mi calidad de director del Trabajo de Titulación “MODELACIÓN PREDICTIVA: ESQUEMA BASADO EN LA DEMANDA, PRODUCCIÓN Y UNIDADES DEFECTUOSAS PARA LA OPTIMIZACIÓN DEL SUMINISTRO Y PRODUCCIÓN” presentado por Llerena Poveda Carlos Enrique, para optar por el Título Magíster en Ingeniería Industrial con mención en Logística y Cadena de Suministro,

CERTIFICO

Que dicho Trabajo de Titulación ha sido revisado en todas sus partes y considero que reúne los requisitos y méritos suficientes para ser sometido a la presentación pública y evaluación por parte los Examinadores que se designe.

Ambato, 28 de abril del 2026

.....

Mgtr. Proaño Altamirano Gladys Elizabeth.

DIRECTORA

DECLARACIÓN DE AUTENTICIDAD

Quien suscribe, declaro que los contenidos y los resultados obtenidos en el presente Trabajo de Titulación, como requerimiento previo para la obtención del Título de Magíster en Ingeniería Industrial con mención en Logística y Cadena de Suministro, son absolutamente originales, auténticos y personales y de exclusiva responsabilidad legal y académica del autor

Ambato, 28 de abril del 2026

.....

Ing. Llerena Poveda Carlos Enrique

1803537826

APROBACIÓN DE EXAMINADORES

El Trabajo de Titulación ha sido revisado, aprobado y autorizada su impresión y empastado, sobre el Tema: MODELACIÓN PREDICTIVA: ESQUEMA BASADO EN LA DEMANDA, PRODUCCIÓN Y UNIDADES DEFECTUOSAS PARA LA OPTIMIZACIÓN DEL SUMINISTRO Y PRODUCCIÓN, previo a la obtención del Título de Magíster en Ingeniería Industrial con mención en Logística y Cadena de Suministro, reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la sustentación del Trabajo de Titulación.

Ambato, 28 de abril del 2026

.....

Mgtr. Ruales Martínez María Belén.

EXAMINADORA

.....

Mgtr. Ocaña Raza Edwin Ramiro.

EXAMINADOR

DEDICATORIA

Dedico este trabajo, a mi madre, quien ha sido y seguirá siendo la fuerza que guía mi vida. En cada etapa, desde los momentos más difíciles hasta los logros alcanzados, ha representado el impulso constante para seguir adelante, formarme como profesional y no rendirme. Es un ejemplo, de sacrificio y amor incondicional principal fundamento de todo lo que hoy soy.

A mis hijos y esposa, mi mayor inspiración, quienes dan sentido a cada esfuerzo y representan la razón más profunda para superarme día a día. Cada meta alcanzada es también un paso hacia el futuro que deseo construir juntos.

A DIOS, desde mi propia comprensión, reconociendo que mientras más conscientes seamos, más cerca estaremos de él.

AGRADECIMIENTO

A mi tutora, por su paciencia, comprensión y acompañamiento profesional brindado a lo largo de este proceso académico.

A mis suegros, por su apoyo constante, el cual ha sido fundamental en el desarrollo y culminación de esta etapa.

A los catedráticos docentes y al coordinador de la carrera de la Universidad Indoamérica, así como a quienes formaron parte de este proceso, por su valioso conocimiento a mi formación y a la culminación de este logro.

ÍNDICE DE CONTENIDOS

PORTADA	i
AUTORIZACIÓN PARA EL REPOSITORIO DIGITAL	ii
APROBACIÓN DEL TUTOR	iii
DECLARACIÓN DE AUTENTICIDAD	iv
APROBACIÓN DE EXAMINADORES	v
DEDICATORIA.....	vi
AGRADECIMIENTO	vii
ÍNDICE DE CONTENIDOS	viii
ÍNDICE DE TABLAS.....	ix
ÍNDICE DE FIGURAS.....	x
RESUMEN EJECUTIVO.....	xi
ABSTRACT	xii
INTRODUCCIÓN	3
METODOLOGÍA	6
RESULTADOS	9
CONCLUSIONES	25
REFERENCIAS BIBLIOGRÁFICAS	27
ANEXOS	32

ÍNDICE DE TABLAS

Tabla No.1: Especificación del estudio.....	7
Tabla No.2: Control de calidad de la base mensual.....	8
Tabla No.3: Periodos excluidos del modelo principal por ausencia de ventas.....	8
Tabla No.4: Estadística descriptiva de las variables del modelo.....	10
Tabla No.5: Matriz de correlaciones del modelo.....	12
Tabla No.6: Coeficientes del modelo OLS.....	16
Tabla No.7: Coeficientes del modelo con errores robustos.....	17
Tabla No.8: Desempeño predictivo del modelo.....	18
Tabla No.9: Diagnóstico de supuestos econométricos.....	21
Tabla No.10: Observaciones con mayor influencia.....	24

ÍNDICE DE FIGURAS

Figura No. 1: Evolución temporal de ventas	10
Figura No. 2: Evolución temporal de producción.....	11
Figura No. 3: Evolución temporal de rechazo.....	11
Figura No. 4: Ventas y producción en el tiempo.....	11
Figura No. 5: Producción vs rechazo.....	13
Figura No. 6: Ventas vs rechazo.....	13
Figura No. 7: Mapa de calor de correlaciones.....	14
Figura No. 8: Distribución de rechazo.....	14
Figura No. 9: Distribución de ventas.....	15
Figura No. 10: Distribución de producción.....	15
Figura No. 11: Valores reales vs predichos.....	19
Figura No. 12: Predicción en prueba.....	19
Figura No. 13: Error por periodo.....	19
Figura No. 14: Residuos vs valores ajustados.....	22
Figura No. 15: Residuos en el tiempo.....	22
Figura No. 16: QQ plot de residuos.....	23
Figura No. 17: Distribución de residuos.....	23
Figura No. 18: Leverage vs Cook's Distance.....	24
Figura No. 19: Observaciones influyentes.....	25

UNIVERSIDAD TECNOLÓGICA INDOAMÉRICA
FACULTAD DE INGENIERÍAS
MAESTRÍA EN INGENIERÍA INDUSTRIAL CON MENCIÓN EN LOGÍSTICA
Y CADENA DE SUMINISTRO

TEMA: MODELACIÓN PREDICTIVA: ESQUEMA BASADO EN LA DEMANDA, PRODUCCIÓN Y UNIDADES DEFECTUOSAS PARA LA OPTIMIZACIÓN DEL SUMINISTRO Y PRODUCCIÓN

AUTOR: Ing. Llerena Poveda Carlos Enrique.

TUTORA: Mgtr. Proaño Altamirano Gladys Elizabeth.

RESUMEN EJECUTIVO

La investigación analizó la relación entre la demanda observada, la producción ejecutada y las unidades defectuosas, con el propósito de aportar evidencia útil para la optimización del suministro y la producción. Se adoptó un enfoque cuantitativo, explicativo y aplicado, bajo un diseño no experimental y longitudinal retrospectivo, utilizando registros mensuales entre enero de 2018 y diciembre de 2024. La variable dependiente fue Rechazo_Total, mientras que Ventas y Produccion_Total actuaron como variables explicativas. Se estimó un modelo de regresión lineal múltiple por OLS con validación temporal 80/20. Los resultados mostraron que Produccion_Total mantuvo un efecto positivo, robusto y estadísticamente significativo sobre los rechazos, mientras que Ventas perdió significancia al controlar por producción. Aunque el modelo alcanzó capacidad explicativa relevante, su rendimiento fuera de muestra fue limitado, evidenciando heterocedasticidad y autocorrelación. Se concluye que la reducción de defectos depende principalmente de intervenir sobre la intensidad productiva y sus tensiones operativas.

DESCRIPTORES: demanda; modelación predictiva; optimización del suministro; producción; unidades defectuosas.

UNIVERSIDAD TECNOLÓGICA INDOAMÉRICA

FACULTY OF ENGINEERING

Master's Degree in Industrial Engineering with major in Logistics and Supply Chain

AUTHOR: LLERENA POVEDA CARLOS ENRIQUE

TUTOR: null PROAÑO ALTAMIRANO GLADYS ELIZABETH

THEME

PREDICTIVE MODELING: A FRAMEWORK BASED ON DEMAND, PRODUCTION, AND DEFECTIVE GOODS FOR SUPPLY AND PRODUCTION OPTIMIZATION

ABSTRACT

This research presents the relationship between observed demand, current production, and defective goods, with the goal of providing valuable insights for optimizing supply and production processes. A quantitative, explanatory, and applied approach was employed, utilizing a non-experimental, longitudinal, retrospective design with monthly data spanning from January 2018 to December 2024. The dependent variable was Total Rejections, while Sales and Total Production were considered explanatory variables. It is worth noting that a multiple linear regression model was estimated using Ordinary Least Squares (OLS) with an 80/20 temporal validation split. The findings showed that Total Production had a strong, positive, and statistically meaningful impact on the number of rejections, while Sales became insignificant once production levels were taken into account. While the model demonstrated significant explanatory power, its performance on data outside the sample was limited, highlighting issues with heteroscedasticity and autocorrelation. It is concluded that defect reduction primarily depends on managing production intensity and addressing the associated operational pressures.

KEYWORDS: defective goods, demand, predictive modeling, supply optimization, and production.



Artículo Científico

Modelación predictiva: esquema basado en la demanda, producción y unidades defectuosas para la optimización del suministro y producción

Predictive modeling: a scheme based on demand, production, and defective units for supply and production optimization

Modelagem preditiva: esquema baseado na demanda, produção e unidades defeituosas para a otimização do suprimento e da produção

***** 1*, ***** 2, ***** 3, ***** 4

¹*****. Correo: ****@unitru.edu.pe. https://orcid.org/000*****96. Trujillo-Perú.

* Datos de correspondencia: ****@unitru.edu.pe; Tel.: (+*****)

Recibido: 2025-08-27

Aceptado: 2026-03-02

Publicado: 2026-04-12

Como citar: *****

Resumen: La investigación analizó la relación entre la demanda observada, la producción ejecutada y las unidades defectuosas, con el propósito de aportar evidencia útil para la optimización del suministro y la producción. Se adoptó un enfoque cuantitativo, explicativo y aplicado, bajo un diseño no experimental y longitudinal retrospectivo, utilizando registros mensuales entre enero de 2018 y diciembre de 2024. La variable dependiente fue Rechazo_Total, mientras que Ventas y Produccion_Total actuaron como variables explicativas. Se estimó un modelo de regresión lineal múltiple por OLS con

validación temporal 80/20. Los resultados mostraron que Produccion_Total mantuvo un efecto positivo, robusto y estadísticamente significativo sobre los rechazos, mientras que Ventas perdió significancia al controlar por producción. Aunque el modelo alcanzó capacidad explicativa relevante, su rendimiento fuera de muestra fue limitado, evidenciando heterocedasticidad y autocorrelación. Se concluye que la reducción de defectos depende principalmente de intervenir sobre la intensidad productiva y sus tensiones operativas.

Palabras clave: modelación predictiva; demanda; producción; unidades defectuosas; optimización del suministro.

Abstract: This study examined the relationship between observed demand, executed production, and defective units in order to provide useful evidence for supply and production optimization. A quantitative, explanatory, and applied approach was adopted under a non-experimental, retrospective longitudinal design using monthly records from January 2018 to December 2024. Rechazo_Total was defined as the dependent variable, while Ventas and

Produccion_Total were used as explanatory variables. A multiple linear regression model estimated by OLS was implemented with an-80/20 temporal validation split. The findings showed that Produccion_Total maintained a positive, robust, and statistically significant effect on total rejections, whereas Ventas lost significance once production was controlled for. Although the model achieved relevant explanatory capacity, its out-of-sample predictive performance remained limited, with evidence of heteroscedasticity and autocorrelation. It is concluded that defect reduction depends mainly on interventions focused on production intensity and the operational pressures generated within the manufacturing process.

Keywords: predictive modeling; demand; production; defective units; supply optimization.

Resumo: A pesquisa analisou a relação entre a demanda observada, a produção executada e as unidades defeituosas, como objetivo de gerar evidências úteis para a otimização do suprimento e da produção. Adotou-se uma abordagem quantitativa, explicativa e aplicada, sob um desenho não experimental e longitudinal retrospectivo, utilizando registros mensais de janeiro de 2018 a dezembro de 2024. A variável dependente foi Rechazo_Total, enquanto Ventas e Produccion_Total foram utilizadas com variáveis explicativas. Estimou-se um modelo de regressão linear múltipla por OLS com validação temporal de 80/20. Os resultados mostraram que Produccion_Total manteve um efeito positivo, robusto e estatisticamente significativo sobre os rejeitos, enquanto Ventas perdeu significância ao se controlar a produção. Embora o modelo tenha alcançado capacidade explicativa relevante, seu desempenho fora da amostra foi limitado, com evidências de heterocedasticidade e autocorrelação. Conclui-se que a

redução dos defeitos depende principalmente de intervenções sobre a intensidade produtiva e as tensões operacionais do processo. *Palavras-chave:* modelagem preditiva; demanda; produção; unidades defeituosas; otimização do suprimento.

Introducción

La literatura revisada sitúa la predicción de la demanda como el punto de partida de cualquier esquema serio de optimización del suministro y la producción. En este corpus, la demanda deja de ser tratada como un dato fijo y pasa a entenderse como un fenómeno dinámico, sensible a factores comerciales, territoriales, energéticos y macroeconómicos, lo que obliga a migrar desde pronósticos lineales a modelos con mayor capacidad para capturar no linealidad, ruido e incertidumbre. En términos analíticos, esta primera línea de trabajos muestra que el valor del pronóstico no reside solo en anticipar ventas, sino en convertir esa anticipación en decisiones sobre capacidad, inventarios y asignación de recursos. Desde esa perspectiva, la literatura converge en una misma conclusión: cuando la demanda se estima con baja precisión, se amplifican los errores aguas abajo en compras, programación y costos; cuando se estima con mayor robustez, la cadena opera con menos fricción y con mayor capacidad de respuesta. Esta regularidad es especialmente importante para un estudio que articula demanda, producción y unidades defectuosas, porque confirma que el eslabón inicial del sistema productivo es la calidad del pronóstico y no únicamente la eficiencia interna de la planta (Nebri et al., 2024; Swami et al., 2024; Syahputra et al., 2025; Mendil et al., 2022; Salunkhe et al., 2025).

Un segundo bloque temático desplaza la atención desde la demanda final hacia el consumo de insumos, la planificación de materias primas y la gestión de abastecimiento. Aquí la discusión se vuelve más cercana al problema central del presente tema, porque los estudios revisados muestran que la organización productiva no se optimiza solamente con conocer cuánto se venderá, sino con anticipar cuánto material deberá comprarse, cuándo deberá entrar al sistema y bajo qué volatilidad operará el entorno. La evidencia sugiere que el pronóstico del uso de materia prima es una bisagra metodológica entre la demanda y la producción, ya que traduce señales de mercado en requerimientos concretos de aprovisionamiento. A la vez, estos trabajos revelan que la relación entre consumo de insumos y volumen producido no es mecánica, sino modulada por la estructura del producto, los cambios de mezcla, la estacionalidad y la incertidumbre del mercado. Por ello, el corpus revisado permite afirmar que cualquier modelo predictivo orientado a la optimización del suministro y la producción gana solidez cuando incorpora explícitamente la lógica de materiales, evitando tratar la producción como una variable abstracta desligada de su base física de abastecimiento (Alfiansyah et al., 2025; Zulfiqar et al., 2024; Kang, 2025; Zhang & Gu, 2022; Fu et al., 2025).

Un tercer eje reúne estudios donde la optimización ya no se limita al pronóstico, sino que se expande hacia políticas de reabastecimiento, programación multiperiodo, evaluación de proveedores y gestión de calidad operativa. Este conjunto es particularmente valioso porque muestra que la predicción solo genera valor cuando se acopla a reglas de decisión que transforman los resultados del modelo en acciones sobre compras, lotes, reposición, transporte o selección de socios de suministro. En esta línea, el corpus sugiere que la eficiencia productiva depende de una arquitectura integrada en la que los modelos predictivos alimentan mecanismos de optimización y control, y no de herramientas aisladas sin conexión con la operación. Además, la revisión deja ver un hallazgo especialmente relevante para el variable “unidades defectuosas”: la literatura internacional todavía tiende a operacionalizar los problemas de calidad más como fallas inminentes, incumplimientos de proveedores o riesgos de abastecimiento que como defectos de producción medidos directamente en la línea. Esa constatación constituye un vacío útil para el presente estudio, porque legitima la pertinencia de introducir la variable de defectos como un componente explícito del modelo y no como una consecuencia marginal de la producción (Presbitero et al., 2025; Abassi et al., 2025; Ramakrishnan et al., 2024; Shen et al., 2025; Larbi et al., 2025).

Un cuarto grupo de investigaciones añade un matiz decisivo: la predicción no opera de forma autónoma, sino dentro de marcos de apoyo a la decisión donde intervienen criterios ergonómicos, comportamiento del usuario, razonamiento multicriterio y manejo de ambigüedad. Este giro es importante porque amplía el debate desde la precisión estadística hacia la calidad de la decisión gerencial. Desde esta perspectiva, la utilidad de un modelo no se agota en reducir error, sino en ofrecer insumos interpretables para decidir bajo restricciones reales. La revisión muestra que, conforme crece la complejidad del entorno productivo, también aumenta la necesidad de modelos híbridos y marcos de decisión que integren datos, juicios expertos y evaluación multicriterio. En consecuencia, el aporte teórico para el presente tema no es solo metodológico, sino también epistemológico: un esquema predictivo basado en demanda, producción y unidades defectuosas será más robusto si se diseña como sistema de apoyo gerencial y no solo como ejercicio econométrico. En otras palabras, la optimización del suministro y la producción exige combinar capacidad predictiva con gobernanza analítica de la decisión (Zhang, Joneurairatana, & Vongphantuset, 2024; Huang & Yue, 2024; Prabha et al., 2026; Kanade et al., 2026; Kamal et al., 2023).

El quinto conjunto temático, concentrado en sistemas agroalimentarios, lácteos, biomasa y producción alimentaria, refuerza una idea transversal: la modelación predictiva adquiere mayor relevancia cuanto más sensibles son los procesos a desperdicio, perecibilidad, seguridad alimentaria y sostenibilidad. En estos estudios, la analítica predictiva no se presenta únicamente como tecnología de eficiencia, sino como mecanismo para estabilizar sistemas sometidos a variabilidad biológica, presión ambiental y exigencias de trazabilidad. De este modo, la literatura confirma que predecir producción, abastecimiento o desempeño no es un lujo técnico, sino una condición para sostener continuidad operativa y uso racional de recursos. Para el tema de investigación planteado, esta evidencia es importante porque desplaza la discusión desde una lógica meramente industrial hacia una comprensión más amplia de la optimización, entendida como equilibrio entre capacidad, calidad,

costo y sostenibilidad. La lección que emerge es clara: los modelos predictivos más útiles son aquellos que no separan la eficiencia de la resiliencia, ni la producción de sus implicaciones ambientales y de calidad, aspecto especialmente pertinente cuando se incorpora la variable de unidades defectuosas como expresión concreta de ineficiencia del sistema (Sinha & Srivastava, 2025; Serrano-Torres et al., 2025; Yadav et al., 2024; Vijayvargiya et al., 2025; Wang, 2024).

Un sexto bloque introduce variables exógenas que complejizan el debate y muestran que la optimización productiva no puede explicarse solo con información interna de la empresa. La reducción de pérdidas postcosecha, la predicción de rasgos agrícolas afectados por el clima, la anticipación de precios en cadenas agroindustriales, el efecto del cambio climático sobre rendimientos y la coordinación “from farm to fork” evidencian que los sistemas de suministro y producción están atravesados por factores ambientales, territoriales e institucionales que alteran tanto la demanda como la disponibilidad y calidad de la oferta. Esta literatura resulta especialmente útil para fundamentar la necesidad de modelos multivariados, porque demuestra que el desempeño operativo rara vez depende de una sola dimensión. En términos analíticos, los estudios revisados enseñan que la planeación productiva mejora cuando incorpora señales externas que permiten anticipar quiebres, pérdidas o tensiones de mercado antes de que estos se materialicen en costos, desabastecimiento o desperdicio. Así, el problema investigativo deja de ser únicamente cuánto producir, para convertirse en una pregunta más amplia sobre cómo coordinar producción, abastecimiento y calidad bajo condiciones cambiantes (Al Shoffe & Johnson, 2024; Zhang, Hauvermale, et al., 2024; Warren-Vega et al., 2022; Shah et al., 2025; Kumar et al., 2025).

Finalmente, el corpus más prospectivo, vinculado con bioeconomía circular, biofuels, supply chains sostenibles, inteligencia artificial generativa e Industria 4.0/5.0, permite identificar el principal vacío que justifica el presente tema. Aunque la literatura reciente exhibe entusiasmo por la incorporación de IA y aprendizaje automático en la gestión productiva, la mayor parte de los estudios aún trabaja dimensiones fragmentadas: unos priorizan la demanda, otros la sostenibilidad, otros la eficiencia logística, y otros la centralidad del factor humano. Son menos frecuentes los trabajos que integran, en una sola arquitectura predictiva, la demanda esperada, la capacidad de producción y la generación de unidades defectuosas como variables interdependientes de la misma decisión operativa. Por ello, la revisión permite sostener que el aporte potencial del estudio no reside solo en aplicar un modelo, sino en proponer una lógica de integración: entender que el suministro se optimiza cuando la demanda prevista conversa con la producción realizable y con la calidad efectivamente obtenida. En ese sentido, la literatura no clausura el problema; por el contrario, abre espacio para un esquema predictivo más articulado, operacional y cercano a la realidad de los sistemas manufactureros contemporáneos (Keohavong, 2026; Machado et al., 2025; Kosuri et al., 2025; Chahal et al., 2025; Keshmiry & Hassani, 2025). Observando la implicancia que tienen las variables en el campo, se determina como objetivo modelar la relación entre la demanda observada con la producción y los defectos, para tener un acercamiento a la lógica funcional de la organización.

Metodología

La investigación se estructuró bajo un enfoque cuantitativo, con alcance explicativo y orientación aplicada, puesto que se propuso identificar y modelar la relación funcional existente entre la demanda observada, la producción ejecutada y las unidades defectuosas generadas en el proceso operativo. Su carácter aplicado se fundamentó en que el propósito no fue únicamente describir la dinámica histórica de las variables, sino producir evidencia analítica útil para la optimización del suministro y la producción, particularmente en contextos donde la toma de decisiones requiere anticipar el comportamiento de los rechazos y comprender sus determinantes inmediatos. En este sentido, el estudio se ubicó en la intersección entre análisis estadístico, control operativo y apoyo a la gestión productiva.

Desde el punto de vista del diseño, se adoptó un esquema no experimental y longitudinal retrospectivo. Fue no experimental porque las variables no fueron manipuladas por los investigadores, sino observadas tal como ocurrieron en los registros históricos del sistema productivo. Fue longitudinal retrospectivo porque se analizó una secuencia de periodos mensuales ya ocurridos, abarcando el intervalo comprendido entre enero de 2018 y diciembre de 2024. Este diseño resultó metodológicamente pertinente para estudiar procesos organizacionales donde los cambios en la demanda, la producción y los defectos no pueden aislarse mediante experimentación, pero sí pueden examinarse a partir de trazas operativas consolidadas en el tiempo. La unidad de análisis fue el mes calendario, dado que este nivel de agregación permite compatibilizar los ritmos de planificación del suministro, ejecución de la producción, seguimiento de ventas y control de calidad.

La fuente de información utilizada fue una estructura analítica con cinco campos fundamentales para el procesamiento inicial: *Año*, *Mes_Num*, *Produccion_Total*, *Rechazo_Total* y *Ventas*. Estas variables se consideraron suficientes para estimar el modelo central del estudio, en coherencia con el objetivo de evaluar un esquema predictivo basado en demanda, producción y defectos. La variable dependiente fue *Rechazo_Total*, entendida como el número total de unidades defectuosas o rechazadas por periodo. Como variables explicativas se utilizaron *Ventas*, asumida como aproximación operativa de la demanda efectivamente observada, y *Produccion_Total*, definida como el volumen

total fabricado durante cada mes. Esta especificación respondió a una lógica sustantiva clara: si la demanda presiona al sistema y la producción intensifica la operación, entonces ambas dimensiones pueden asociarse con la aparición de defectos, aunque no necesariamente con la misma magnitud o significancia estadística. Se resume la arquitectura metodológica del modelo empleado.

Tabla 1. *Especificación del estudio*

Especificación	Descripción
Variable dependiente	Rechazo_Total
Variables explicativas	Ventas, Produccion_Total
Unidad de análisis	Mes
Cobertura temporal	Enero de 2018 a diciembre de 2024
Base agregada inicial	79 periodos mensuales
Base final para estimación	74 periodos mensuales
Método principal	Regresión lineal múltiple por OLS
Validación	Corte temporal 80% entrenamiento y 20% prueba
Software analítico	Python, Statsmodels, Scikit-learn, Plotly

El procesamiento de la información inició con una fase de validación y limpieza. Primero se verificó la existencia de las columnas mínimas necesarias para la estimación. Luego, las variables numéricas fueron convertidas explícitamente a formato cuantitativo mediante coerción controlada de errores, con el fin de evitar inconsistencias derivadas de celdas mixtas o registros no estandarizados. Posteriormente, se construyó una variable de fecha usando la combinación de *Año* y *Mes_Num*, asignando el primer día de cada mes como referencia temporal. Este paso fue decisivo para garantizar el orden cronológico de la serie y permitir tanto la agregación mensual como la validación predictiva basada en secuencia temporal. Una vez generada la fecha, la base se ordenó ascendentemente para preservar la continuidad histórica del fenómeno estudiado.

En la segunda fase se ejecutó una agregación mensual mediante sumatoria de las variables principales. La decisión metodológica de agregar por mes se justificó por dos razones. En primer lugar, porque el propósito se centra en la optimización del suministro y la producción a escala táctica y no en la microvariación diaria o transaccional. En segundo lugar, porque la dinámica de los rechazos adquiere mayor

interpretabilidad cuando se examina en conjunto con la producción total y la demanda acumulada del periodo. Como resultado de este procedimiento se obtuvo una base mensual de 79 observaciones. Sin embargo, no todos los meses contaban con información completa para la variable de ventas. En particular, se identificaron cinco periodos sin datos observados de ventas: junio de 2020, agosto de 2020, septiembre de 2020, abril de 2021 y mayo de 2021. Dado que la variable *Ventas* forma parte del sistema explicativo principal, estos periodos fueron excluidos de la estimación econométrica para evitar imputaciones artificiales o supuestos no respaldados por la base original. Se sintetiza este proceso.

Tabla 2. *Control de calidad de la base mensual*

Temporalidad	Valor
Periodos mensuales agregados	79
Periodos con información completa para el modelo	74
Periodos excluidos por ausencia de ventas	5
Primer periodo de la serie	2018-01
Último periodo de la serie	2024-12

Tabla 3. *Periodos excluidos del modelo principal por ausencia de ventas*

Temporalidad	Produccion_Total	Rechazo_Total
2020-06	16330	107
2020-08	9434	0
2020-09	6512	3
2021-04	13541	47
2021-05	23317	44

La validación del modelo se planteó con criterio estrictamente temporal, evitando una partición aleatoria que hubiese mezclado información futura con observaciones pasadas. El 80% inicial de la serie se utilizó para entrenamiento y el 20% final para prueba. Así, el conjunto de entrenamiento comprendió 59 observaciones entre enero de 2018 y septiembre de 2023, mientras que el conjunto de prueba incluyó 15 observaciones entre octubre de 2023 y diciembre de 2024. Esta decisión metodológica fue especialmente importante porque el propósito del estudio no se limita a explicar relaciones contemporáneas, sino a evaluar la utilidad del modelo como herramienta de apoyo para anticipar

el comportamiento de los rechazos. La evaluación predictiva se realizó mediante cuatro indicadores: coeficiente de determinación (R^2), error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y error porcentual absoluto medio (MAPE).

Resultados

Caracterización descriptiva de la base mensual

La base mensual consolidada reveló un sistema operativo con variabilidad sustantiva en sus tres dimensiones centrales: demanda, producción y defectos. De las 79 observaciones agregadas, 74 fueron utilizables para el modelo principal, lo que representa una cobertura analítica suficientemente amplia para examinar tendencias de mediano plazo. La Tabla 4 muestra que la variable *Ventas* registró una media de \$62,125.14 y una desviación estándar de \$70,914.75, lo que da cuenta de una demanda observada altamente fluctuante. El valor mínimo de ventas fue \$-22.00, situación que probablemente responde a ajustes, devoluciones o correcciones operativas, mientras que el valor máximo alcanzó \$246,051.00, reflejando meses de fuerte dinamismo comercial.

En el caso de *Produccion_Total*, la media se situó en 82,663.12 unidades, con una desviación estándar de 51,339.77, una mediana de 87,008.50 y un máximo de 195,450.00. Este patrón revela que la capacidad productiva no se mantuvo constante, sino que atravesó fases de intensificación y contracción. Por su parte, *Rechazo_Total* registró una media de 1,914.14 unidades defectuosas por mes, con una desviación estándar de 1,357.95 y un rango que osciló entre 0 y 4,909 unidades. En términos sustantivos, ello indica que los defectos no constituyen un fenómeno marginal dentro de la operación, sino una dimensión con magnitud suficiente para justificar su estudio específico y su integración dentro del sistema de decisión productiva.

Tabla 4. Estadísticos descriptivos de las variables del modelo

	n	Media	Desv. Estándar	Mínimo	Percentil 25	Mediana	Percentil 75	Máximo
Ventas	74	62125.14	70914.75	-22.00	2529.00	24601.50	119780.50	246051.00
Produccion_Total	74	82663.12	51339.77	14.00	42915.00	87008.50	117102.75	195450.00
Rechazo_Total	74	1914.14	1357.95	0.00	888.50	1733.50	2953.75	4909.00

La lectura temporal de las series reforzó la interpretación anterior. La Figura 1 mostró una trayectoria irregular, con meses de expansión pronunciada y otros de contracción severa. La Figura 2 evidenció que la operación fabril respondió también con amplitud variable a lo largo del tiempo. A su vez, la Figura 3 reveló que el volumen de defectos no siguió una tendencia plana, sino que se incrementó o redujo según configuraciones operativas específicas. La Figura 4 añadió una evidencia importante: la serie de ventas y la de producción no siempre se desplazaron de manera perfectamente sincronizada. Esta falta de paralelismo sugiere que la lógica del rechazo no depende de una sola dimensión y que el sistema productivo puede entrar en tensiones donde la producción supera o desacopla parcialmente la demanda observada, con posibles implicaciones sobre eficiencia, inventarios y control de calidad.




Figura 1. Evolución temporal de Ventas




Figura 2. Evolución temporal de Produccion Total




Figura 3. Evolución temporal de Rechazo Total




Figura 4. Ventas y Produccion en el Tiempo

Estructura de relación entre demanda, producción y defectos

El análisis correlacional confirmó que la intensidad productiva mantiene una asociación más fuerte con los defectos que la demanda observada. Tal como se muestra en la Tabla 5, la correlación entre *Produccion_Total* y *Rechazo_Total* fue de 0.7789, valor que puede considerarse alto dentro de estudios operativos de datos agregados. En contraste, la correlación entre *Ventas* y *Rechazo_Total* fue de 0.6025, lo que indica una relación positiva de intensidad moderada. La relación entre *Ventas* y *Produccion_Total* alcanzó 0.7619, señalando que ambas variables comparten una lógica de comovimiento importante, aunque no perfectamente equivalente.

Tabla 5. Matriz de correlaciones del modelo

Variables	Ventas	Produccion_Total	Rechazo_Total
Ventas	1.0000	0.7619	0.6025
Produccion_Total	0.7619	1.0000	0.7789
Rechazo_Total	0.6025	0.7789	1.0000

La evidencia gráfica fue congruente con estos resultados. En la Figura 5. Produccion Total vs Rechazo Total se observó una nube de puntos con pendiente positiva bien definida, lo que respalda la hipótesis de que un mayor volumen producido tiende a asociarse con un mayor volumen de unidades defectuosas. La Figura 6. Ventas vs Rechazo Total también mostró una relación ascendente, aunque con mayor dispersión alrededor de la tendencia. La Figura 7. Mapa de Calor Correlaciones sintetizó visualmente esta estructura y permitió advertir que el componente productivo ocupa una posición más próxima al comportamiento de los rechazos que la demanda comercial. Metodológicamente, este hallazgo anticipaba que la variable *Produccion_Total* tendría una mayor probabilidad de conservar significancia en el modelo multivariado, una vez controlada la covariación con ventas.




Figura 5. *Produccion Total vs Rechazo Total*




Figura 6. *Ventas vs Rechazo Total*




Figura 7. Mapa de Calor Correlaciones

Las distribuciones observadas en la Figura 8-10 aportaron un matiz adicional. Ninguna de las tres variables presentó una configuración completamente simétrica, y todas mostraron señales de heterogeneidad y posible influencia de valores extremos. Esto resulta habitual en sistemas productivos reales, donde la operación no ocurre en un entorno estable o estacionario, sino bajo variaciones de calendario, cambios de capacidad, alteraciones de la demanda y eventos puntuales que modifican la relación entre variables. En términos analíticos, esta evidencia justificó la incorporación de errores robustos y la revisión detallada de supuestos.




Figura 8. Distribución Rechazo Total




Figura 9. *Distribución Ventas*




Figura 10. *Distribución Producción Total*

Estimación del modelo de regresión lineal múltiple

El modelo OLS estimado alcanzó un $R^2 = 0.6069$ y un R^2 ajustado = 0.5958, lo que significa que cerca del 60.7% de la variabilidad observada en *Rechazo_Total* pudo ser explicada de manera conjunta por *Ventas* y *Produccion_Total*. Este nivel de ajuste debe considerarse relevante en un contexto aplicado, sobre todo porque el fenómeno modelado responde a dinámicas operativas complejas que difícilmente pueden ser capturadas por completo con solo dos predictores contemporáneos. Además, la prueba global del modelo fue estadísticamente significativa ($F = 54.8043$; $p < 0.001$), lo que confirma que el conjunto de variables

explicativas aporta capacidad informativa sobre la variable dependiente.

La Tabla 6 muestra que el intercepto no resultó significativo en la especificación clásica, mientras que *Produccion_Total* sí presentó un coeficiente positivo y altamente significativo. En cambio, *Ventas* exhibió un efecto positivo muy pequeño y estadísticamente no significativo. Esta diferencia entre ambos predictores constituye uno de los hallazgos más importantes del estudio.

Tabla 6. *Coeficientes del modelo OLS*

Variable	Coeficiente	Error estándar	t	p-valor	IC 95% inferior	IC 95% superior
Constante	221.3613	198.8388	1.1133	0.2693	-175.1121	617.8346
Ventas	0.0004	0.0022	0.1877	0.8516	-0.0040	0.0048
Produccion_Total	0.0202	0.0030	6.6363	0.0000	0.0141	0.0262

Desde la perspectiva sustantiva, el coeficiente de *Produccion_Total* indica que, manteniendo constantes las ventas, un incremento de una unidad en la producción se asocia con un aumento promedio de 0.0202 unidades en el rechazo total. Expresado de forma más intuitiva, un aumento de 1,000 unidades producidas se asocia, en promedio, con aproximadamente 20.2 unidades defectuosas adicionales, bajo el supuesto de mantener estable el resto de las condiciones representadas en el modelo. Este resultado es consistente con una lógica operativa donde el aumento de la carga productiva incrementa la exposición del sistema a fallas, errores, mermas o tensiones de control de calidad.

Por el contrario, el efecto de *Ventas* fue estadísticamente irrelevante dentro de la especificación multivariada. Aunque la variable mostró asociación positiva a nivel correlacional, perdió capacidad explicativa una vez controlada la producción. Esto sugiere que la demanda observada incide sobre los rechazos más bien de forma indirecta, probablemente a través de la presión que ejerce sobre el volumen producido, y no como un determinante autónomo de los defectos. En términos metodológicos, este hallazgo es importante porque evita sobredimensionar el papel de la demanda cuando el mecanismo más inmediato de generación de rechazos parece residir en la intensidad del proceso productivo.

La estimación con errores robustos HC3 reforzó la estabilidad de esta conclusión. La **Tabla 7** muestra que *Produccion_Total* permaneció altamente significativa ($p < 0.001$), mientras *Ventas* siguió siendo no significativa. Incluso el intercepto pasó a ser significativo bajo la corrección robusta, aunque este punto tiene menor relevancia sustantiva que la persistencia del efecto de producción.

Tabla 7. Coeficientes del modelo con errores robustos HC3

Variables	Coeficiente	Error robusto HC3	p- valor	IC robusto 95% inferior	IC robusto 95% superior
Constante	221.3613	106.7886	0.0418	8.4309	434.2916
Ventas	0.0004	0.0029	0.8872	-0.0054	0.0062
Produccion_Total	0.0202	0.0028	0.0000	0.0145	0.0258

Capacidad predictiva y validación temporal

El rendimiento del modelo fue heterogéneo al comparar su comportamiento dentro de la muestra de entrenamiento y fuera de ella. La partición temporal asignó 59 observaciones al entrenamiento, cubriendo desde enero de 2018 hasta septiembre de 2023, y 15 observaciones al conjunto de prueba, entre octubre de 2023 y diciembre de 2024. Tal como se resume en la Tabla 8, el ajuste en entrenamiento fue relativamente sólido, con un $R^2 = 0.7126$. Sin embargo, el rendimiento fuera de muestra se deterioró de manera clara, arrojando un $R^2 = -0.3456$. Este valor negativo significa que, en el tramo de prueba, el modelo predijo peor que una referencia ingenua basada en la media del conjunto observado.

Tabla 8. *Desempeño predictivo del modelo*

Resultados	Valor
Periodos de entrenamiento	59
Rango temporal entrenamiento	2018-01 a 2023-09
Periodos de prueba	15
Rango temporal prueba	2023-10 a 2024-12
R ² Train	0.7126
R ² Test	-0.3456
MAE Test	1187.8290
RMSE Test	1417.9759
MAPE Test (%)	37.2430

El MAE de 1187.8290 y el RMSE de 1417.9759 indican que los errores absolutos y cuadráticos del conjunto de prueba fueron considerablemente altos en relación con el promedio de rechazo mensual. De manera consistente, el MAPE de 37.2430% sugiere que el error relativo del modelo se encuentra todavía en un nivel elevado para propósitos de predicción operativa fina. Esta situación no invalida la utilidad explicativa del modelo, pero sí obliga a distinguir entre capacidad de interpretación estructural y capacidad de pronóstico preciso. En otras palabras, el modelo resulta útil para entender qué variable empuja con mayor fuerza el comportamiento del rechazo, pero todavía no alcanza un desempeño suficientemente robusto como para constituirse, por sí solo, en una herramienta predictiva de alta precisión para todos los periodos futuros.

La evidencia visual refuerza esta lectura. La Figura 11 mostró que en el tramo de entrenamiento la línea estimada sigue razonablemente el comportamiento general de la serie. No obstante, en el tramo de prueba se observan separaciones visibles entre valores reales y predichos. La Figura 12 evidenció dispersión significativa respecto de la diagonal ideal, lo que sugiere subestimaciones y sobrestimaciones en meses concretos. De igual forma, la Figura 13 reveló que el error no se distribuyó uniformemente, sino que se concentró con especial intensidad en ciertos meses recientes, lo que sugiere cambios estructurales, shocks operativos o componentes temporales no modelados explícitamente.




Figura 11. Valores reales vs predichos Train Test




Figura 12. Real vs predicho en Prueba




Figura 13. Error de Predicción por Periodo

Diagnóstico econométrico del modelo

La revisión de supuestos proporcionó una lectura más fina sobre las fortalezas y límites del ajuste obtenido. En primer lugar, la multicolinealidad no apareció como un problema severo. Los VIF de *Ventas y Produccion_Total* fueron ambos de 2.3841, valores claramente inferiores a los umbrales de alerta más utilizados. Aunque el resumen OLS reportó un número de condición elevado, este resultado debe interpretarse con cautela, ya que también puede verse influido por la escala de las variables y no necesariamente por colinealidad sustantiva grave. Por tanto, el modelo no presenta evidencia de inestabilidad severa en los coeficientes debida a redundancia lineal entre predictores.

En segundo lugar, la homocedasticidad sí resultó comprometida. La prueba de Breusch–Pagan arrojó un F p-valor = 0.0125, lo que sugiere varianza no constante de los errores. Esto implica que la dispersión residual cambia a lo largo del rango de valores ajustados y, por tanto, la inferencia clásica puede subestimar o sobreestimar la verdadera incertidumbre de los parámetros. Precisamente por esta razón, la inclusión de errores robustos HC3 fue metodológicamente adecuada y fortaleció la credibilidad inferencial del resultado principal asociado a la producción.

En tercer lugar, la normalidad residual mostró un cumplimiento imperfecto. La prueba de Jarque–Bera produjo un p-valor = 0.0487, valor apenas inferior al umbral convencional de 0.05. Esta evidencia indica que los residuos se apartan moderadamente de una distribución normal, posiblemente como consecuencia de asimetría, presencia de meses atípicos o estructura temporal no completamente absorbida por la especificación lineal. En aplicaciones de corte operativo, esta desviación no invalida automáticamente el modelo, pero sí aconseja prudencia al interpretar intervalos y pruebas basadas en supuestos gaussianos estrictos.

El punto más crítico emergió en la independencia de los errores. El estadístico de Durbin–Watson = 0.5692 sugiere una autocorrelación positiva marcada, y esta conclusión fue reforzada por la prueba de Breusch–Godfrey, cuyo p-valor fue prácticamente cero. En términos sustantivos, esto indica que los errores del modelo no son independientes entre periodos, sino que conservan memoria temporal. Dicho de otra forma, parte del rechazo observado en un mes parece

estar relacionado con dinámicas no modeladas que persisten desde meses previos. Esta es una evidencia muy importante, porque sugiere que el sistema tiene una estructura temporal más rica que la capturada por una regresión contemporánea simple.

Finalmente, la prueba RESET arrojó un p -valor = 0.0506, valor ubicado exactamente en el borde de la significancia. Esta situación sugiere que la forma funcional lineal es una aproximación razonable, pero potencialmente incompleta. No existe evidencia contundente para rechazarla, aunque sí una señal suficiente para considerar que podrían existir no linealidades, términos de interacción, estacionalidad o rezagos omitidos que mejorarían el comportamiento del modelo (ver Tabla 9).

Tabla 9. *Diagnóstico de supuestos econométricos resume estos resultados.*

Supuestos econométricos	Valor	Lectura analítica
VIF Ventas	2.3841	Sin evidencia de colinealidad severa
VIF Produccion_Total	2.3841	Sin evidencia de colinealidad severa
Breusch-Pagan LM p-valor	0.0136	Heterocedasticidad presente
Breusch-Pagan F p-valor	0.0125	Heterocedasticidad presente
Jarque-Bera p-valor	0.0487	Normalidad residual no plenamente satisfecha
Durbin-Watson	0.5692	Autocorrelación positiva marcada
Breusch-Godfrey p-valor	0.0000	Evidencia fuerte de autocorrelación
RESET p-valor	0.0506	Forma lineal aceptable, pero en el límite

La evidencia gráfica apoyó estas conclusiones. La Figura 14 mostró una dispersión que no permanece estrictamente constante a lo largo del rango estimado, lo que es coherente con heterocedasticidad. La Figura 15 evidenció secuencias de residuos con el mismo signo durante varios periodos, rasgo compatible con autocorrelación positiva. La Figura 16 y la Figura 17 reflejaron desviaciones moderadas respecto a la normalidad teórica, especialmente en las colas de la distribución. En conjunto, estas señales confirman que el modelo cumple una función explicativa inicial valiosa, aunque no agota la complejidad temporal del fenómeno estudiado.




Figura 14. *Residuos vs Valores Ajustados*




Figura 15. *Residuos en el Tiempo*




Figura 16. *QQ Plot de Residuos*




Figura 17. *Distribución de Residuos*

Observaciones influyentes y lectura operativa del sistema

El análisis de leverage y distancia de Cook permitió identificar meses que ejercen un peso desproporcionado sobre el ajuste del modelo. La observación más influyente correspondió a julio de 2024, con una distancia de Cook de 0.3304 y leverage de 0.1324, acompañada por un nivel de ventas de 237,277.00, una producción de 125,929 y un rechazo de 4,909 unidades. Este mes combina intensidad comercial alta, volumen productivo elevado y el máximo rechazo de toda la serie,

razón por la cual su influencia sobre los coeficientes es especialmente marcada. También destacaron marzo de 2019, enero de 2024, diciembre de 2022 y julio de 2022, entre otros periodos con niveles atípicos de combinación entre producción, ventas y defectos (Ver Tabla 10 y Figura 18-19)

Tabla 10. Observaciones con mayor influencia

Temporalidad	Ventas	Produccion_Total	Rechazo_Total	Cooks_D	Leverage
2024-07	237277.0	125929	4909	0.3304	0.1324
2019-03	173496.0	166227	1910	0.0802	0.0534
2024-01	6542.0	114287	4004	0.0788	0.0700
2022-12	2610.0	81047	3648	0.0543	0.0352
2022-07	196780.0	157738	4739	0.0505	0.0629
2024-09	27130.0	77225	4151	0.0498	0.0192
2022-06	11037.0	84395	3621	0.0434	0.0317
2018-07	167219.0	151406	2007	0.0395	0.0450




Figura 18. *Leverage vs Cook's Distance*




Figura 19. Observaciones más influyentes según Cook's Distance

Conclusiones finales

En conjunto, los resultados permiten sostener que el comportamiento de las unidades defectuosas se encuentra más estrechamente asociado con la intensidad del proceso productivo que con la demanda observada en el corto plazo. En efecto, Produccion_Total se mantuvo estadísticamente significativa en los distintos escenarios de inferencia y exhibió un efecto positivo, robusto y sustantivamente interpretable sobre Rechazo_Total. Por el contrario, Ventas no logró conservar un efecto independiente una vez controlado el nivel de producción, lo que sugiere que la demanda actúa principalmente como una señal de contexto comercial y operativo, antes que como un detonante directo del rechazo. Esta evidencia resulta relevante porque desplaza el eje interpretativo desde una lectura centrada exclusivamente en el mercado hacia una perspectiva orientada a la gestión interna del sistema productivo, donde el incremento de la carga de fabricación parece traducirse en mayores presiones sobre el control de calidad, el uso de recursos, la estabilidad operativa y, en consecuencia, el aumento de unidades no conformes.

No obstante, la validación temporal y los diagnósticos econométricos también muestran que el fenómeno no puede considerarse plenamente capturado mediante una regresión lineal contemporánea simple. El desempeño limitado fuera de muestra, junto con la presencia de heterocedasticidad, no normalidad marginal y, especialmente, una fuerte autocorrelación residual, indica que el rechazo productivo responde asimismo a componentes dinámicos, mecanismos de persistencia temporal y eventos específicos que no son absorbidos por la forma funcional actualmente

especificada. En este sentido, el modelo debe entenderse como una base analítica sólida, técnicamente defendible y útil para explicar el comportamiento medio del sistema, pero no como una representación final ni exhaustiva del esquema predictivo requerido para una planificación integral de la operación.

En términos de contribución, el estudio demuestra que la articulación entre demanda, producción y unidades defectuosas permite construir una lectura cuantitativa consistente del funcionamiento del proceso, aportando evidencia relevante no solo para la optimización de la producción, sino también para la logística interna, el abastecimiento de insumos y la coordinación de la cadena de suministro. Su hallazgo central radica en que la reducción del rechazo no depende únicamente de acompasar la producción con la demanda, sino de intervenir sobre la manera en que la carga productiva se transforma en presión sobre la calidad. Esto implica que una planeación ineficiente de materiales, tiempos, capacidad instalada, flujo de insumos o secuencia operativa puede amplificar desperdicios, reprocesos, sobrecostos y tensiones logísticas a lo largo de la cadena. Por tanto, el valor del modelo no se limita a su capacidad explicativa o predictiva inicial, sino que reside también en su potencial para orientar decisiones estratégicas vinculadas con la programación de la producción, la gestión de inventarios, la adquisición oportuna de suministros y la sincronización entre abastecimiento, fabricación y respuesta al mercado.

Como implicación práctica y como línea futura de desarrollo, los resultados permiten sugerir la conveniencia de avanzar hacia un esquema de planificación operativa de tipo Make-to-Stock controlado (MTS controlado), en el que la producción programada no se defina únicamente a partir de la demanda esperada, sino también del nivel de rechazo previsto en el sistema. Bajo esta lógica, una formulación operativa preliminar podría expresarse como: $\text{Producción requerida} = \text{Ventas pronosticadas} / (1 - \text{tasa de rechazo esperada})$. Aunque esta relación no fue incorporada ni contrastada empíricamente dentro de la regresión estimada en la presente fase, su planteamiento constituye una derivación práctica coherente de los hallazgos obtenidos, ya que permitiría ajustar la producción planificada considerando explícitamente las pérdidas asociadas a defectos. Desde la perspectiva logística y de supply chain, este enfoque podría contribuir a mejorar la estimación de requerimientos de materiales, la programación de compras, la disponibilidad de insumos, la gestión de inventarios de seguridad y la continuidad del flujo operativo, reduciendo quiebres, excesos y desalineaciones entre suministro, producción y despacho. De este modo, la investigación no solo aporta evidencia sobre los determinantes del rechazo, sino que también abre una ruta aplicada para futuros estudios orientados al diseño de modelos de planeación más realistas, integrando rezagos, estacionalidad, variables de proceso y métodos predictivos de mayor complejidad para fortalecer la eficiencia de la cadena de suministro en su conjunto.

Referencias bibliográficas

- Abassi B, Turki S, & Dellagi S. (2025). Optimal Multi-Period Manufacturing–Remanufacturing–Transport Planning in Carbon Conscious Supply Chain: An Approach Based on Prediction and Optimization. *Sustainability (Switzerland)*, 17(11), 5218. <https://doi.org/10.3390/su17115218>
- Al Shoffe Y, & Johnson L.K. (2024). Opportunities for Prediction Models to Reduce Food Loss and Waste in the Postharvest Chain of Horticultural Crops. *Sustainability (Switzerland)*, 16(17), 7803. <https://doi.org/10.3390/su16177803>
- Alfiansyah M.R, Tukino T, Hananto A, & Novalia E. (2025). Implementation of The Seasonal Autoregressive Integrated Moving Average Predictive Model on Raw Material Usage Data at PT. Plastik Karawang Flexindo. *International Journal of Engineering, Science and Information Technology*, 5(3), 12–30. <https://doi.org/10.52088/ijesty.v5i3.867>
- Chahal B.P.S, David A, Singh A, Madaan G, & Singh G. (2025). *Impact of generative AI on food supply chain management*. IGI Global. <https://doi.org/10.4018/979-8-3693-9856-2>
- Fu Y, Ma X, Zhang L, & Shen F. (2025). Research on AGM Decision Fusion Based on LSTM Model and RF Model for Industrial Machine Demand Forecasting. In *Proceedings of the 2nd International Conference on Artificial Intelligence of Things and Computing, AITC 2025* (pp. 6–11). Association for Computing Machinery, Inc. <https://doi.org/10.1145/3762329.3762331>
- Huang S, & Yue H. (2024). Optimizing Strategic Decision-Making in Multinational Corporations through Data MiningBased User Behavior Analysis. *Journal of System and Management Sciences*, 14(1), 579–591. <https://doi.org/10.33168/JSMS.2024.0134>
- Kamal E, Abdel-Gawad A.F, & Zaki S. (2023). Neutrosophic-based Machine Learning Techniques in the Context of Supply Chain Management: A Survey. *International Journal of Neutrosophic Science*, 21(2), 142–160. <https://doi.org/10.54216/IJNS.210213>
- Kanade T.M, Joseph J, Savale T, & Batule R. (2026). AI-Driven Predictive Analytics in Metallurgical Marketing: Enhancing

- Demand Forecasting and Supply Chain Efficiency. In *Communications in Computer and Information Science* (pp. 3–24). Springer Science and Business Media Deutschland GmbH.
https://doi.org/10.1007/978-3-032-17834-3_1
- Kang M. (2025). Research on Prediction Model and Optimization of Enterprise Material Procurement Management Based on Global Linkage. *International Journal of Computational Intelligence Systems*, 18(1), 242. <https://doi.org/10.1007/s44196-025-01010-3>
- Keohavong B. (2026). Digital innovation integration into biotechnology for development of sustainable protein frontiers for poultry nutrition in a circular bioeconomy. *Poultry Science*, 105(2), 106276.
<https://doi.org/10.1016/j.psj.2025.106276>
- Keshmiry A, & Hassani S. (2025). Human-Centric Design Principles in Industry 4.0 and Industry 5.0. In *Computational Intelligence for Analysis of Trends in Industry 4.0 and 5.0* (pp. 275–290). CRC Press.
<https://doi.org/10.1201/9781003533023-11>
- Kosuri S, Prakash N, Ali M.F, Majid A.-H.M, Mary S.S.C, & Dhaaraani R. (2025). An Attention-Driven Hybrid CNN-LSTM Model for Accurate Prediction in Sustainable Supply Chain Management. In *2025 International Conference on Sustainability, Innovation and Technology, ICSIT 2025*. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ICSIT65336.2025.11294902>
- Kumar R, Srinivas K, & Kumar S. (2025). From Farm to Fork: Role of FPOs and Agri-Startups in India. In *Advances in Agri-Food Systems: Volume II* (pp. 113–130). Springer Science+Business Media.
https://doi.org/10.1007/978-981-96-07631_7
- Larbi M, Choi Y, & Cheng C. (2025). Dual Machine Learning Models for IoT Quality and Supply Chain Management. In *Proceedings - Annual Reliability and Maintainability Symposium*. Institute of Electrical and Electronics Engineers Inc.
<https://doi.org/10.1109/RAMS48127.2025.10935020>
- Machado T.J, Diniz A.A.R, & Santos M.D.D. (2025). Artificial Intelligence and Machine Learning in Biofuels as Tools for Advancing Efficiency and Sustainability. In *Artificial Intelligence for Biomass-based Biofuel Production: Current Status and Prospects* (pp. 278–300). CRC Press. <https://doi.org/10.1201/9781003571223-12>

- Mendil M, Mossina L, Nabhan M, & Pasini K. (2022). Robust Gas Demand Forecasting With Conformal Prediction. In *Proceedings of Machine Learning Research* (pp. 169–187). ML Research Press.
- Nebri M.A, Moussaid A, & Bouikhalene B. (2024). Forecasting livestock feed sales using machine learning techniques: an analysis of the Moroccan market. *Indonesian Journal of Electrical Engineering and Computer Science*, 35(2), 1139–1150. <https://doi.org/10.11591/ijeecs.v35.i2.pp1139-1150>
- Prabha D, Katake S.P, Rawat K, Nangare V, Soni A, & Shanthi V. (2026). PREDICTIVE ANALYTICS FOR PRINT SUPPLY CHAIN MANAGEMENT. *ShodhKosh: Journal of Visual and Performing Arts*, 7(1s), 347–356. <https://doi.org/10.29121/shodhkosh.v7.i1s.2026.7099>
- Presbitero A, Syrén A, Dippel H, Awasthi L, Dev S, & Nie Z. (2025). A practical approach to replenishment optimization with extended (R, s, Q) policy and probabilistic models. *Scientific Reports*, 15(1), 44225. <https://doi.org/10.1038/s41598-025-32537-2>
- Ramakrishnan V, Ramasamy N, Dev Anand M, & Santhi N. (2024). Supply Chain Management Efficiency Improvement in the Automobile Industry Using Lean Six Sigma and Artificial Neural Network. *IEEE Transactions on Engineering Management*, 71, 3278–3294. <https://doi.org/10.1109/TEM.2023.3332147>
- Salunkhe K, Gonge S, Maheshwari G, & Kadam K. (2025). Leveraging Economic Factors for Volume Forecasting in Manufacturing Industries. *International Journal of Engineering Trends and Technology*, 73(9), 1–9. <https://doi.org/10.14445/22315381/IJETT-V73I9P101>
- Serrano-Torres G.J, López-Naranjo A.L, Larrea-Cuadrado P.L, & Mazón-Fierro G. (2025). Transformation of the Dairy Supply Chain Through Artificial Intelligence: A Systematic Review. *Sustainability (Switzerland)*, 17(3), 982. <https://doi.org/10.3390/su17030982>
- Shah M.H, Shah W, Syed S, Ullah I, Wang Y, & Wang Y. (2025). Impacts of Climate Change on Rice Production in Pakistan: A Perspective from a Deep Learning Approach. *Atmosphere*, 16(11), 1305. <https://doi.org/10.3390/atmos16111305>
- Shen Y, He L, Xiang H, & Li J. (2025). A multimodel optimization and feature contribution analysis for evaluating outsourced suppliers of equipment manufacturing enterprises. In *Proceedings of SPIE - The International Society for Optical Engineering* (pp. 1378010). SPIE. <https://doi.org/10.1117/12.3072336>

Sinha K, & Srivastava S. (2025). Role of artificial intelligence and modern tools in rice crop production: The future of abiotic stress management. In *Rice Cultivation Under Abiotic Stress: Challenges and Opportunities* (pp. 363–382). Elsevier.
<https://doi.org/10.1016/B978-0-443-21793-7.00023-4>

Swami B, Singh P.D, & Chauhan A. (2024). Predictive modeling of car sales using random forest regression: Leveraging diverse features for accurate sales projections. In *AIP Conference Proceedings* (pp. 020008). American Institute of Physics.
<https://doi.org/10.1063/5.0221801>

Syahputra R.A, Kasmawati R.A, & Sentia P.D. (2025). The application of artificial neural network (ANN) with backpropagation algorithm to predict supply chain demand. *Journal of Optimization in Industrial Engineering*, 18(1), 305–313.
<https://doi.org/10.71720/joie.2025.1127133>

Vijayvargiya S, Sinha S, & Sivakumar V. (2025). The Role of AI and ML in Shaping the Future of the Food Industry. *Current Nutrition and Food Science*, 21(10), 1021–1029.
<https://doi.org/10.2174/0115734013371588250815061734>

Wang J. (2024). Machine Learning Applications in Biomass Supply Chain Management and Optimization. *BioResources*, 19(4), 6961–6963.
<https://doi.org/10.15376/biores.19.4.6961-6963>

Warren-Vega W.M, Aguilar-Hernández D.E, Zárate-Guzmán A.I, Romero-Cano L.A, & Campos-Rodríguez A. (2022).

Development of a Predictive Model for Agave Prices Employing Environmental, Economic, and Social Factors:

Towards a Planned Supply Chain for Agave–Tequila Industry. *Foods*, 11(8), 1138.

<https://doi.org/10.3390/foods11081138>

Yadav S, Rajendran M, Nagpal A, Karthik A, Aravinda K, & Geetha B.T. (2024). Exploring the Potential of Machine

Learning in Enhancing Agricultural Practices and Food Production. In *Proceedings - 2024 13th IEEE International Conference on Communication Systems and Network Technologies, CSNT 2024* (pp. 663–669). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/CSNT60213.2024.10546234>

Zhang B, Hauvermale A.L, Zhang Z, Thompson A, Neely C, Esser A, Pumphrey M, Garland-Campbell K, Yu J, Steber C, & Li X. (2024). Harnessing enviromics to predict

climate-impacted high-profile traits to assist informed decisions in agriculture.
Food and Energy Security, 13(3), e544. <https://doi.org/10.1002/fes3.544>

Zhang J, & Gu X. (2022). Zinc Consumption Forecast of Support Vector Based on Improved Grey Wolf Algorithm

Optimization; [基于改进灰狼算法优化的支持向量机锌耗预测]. *Huadong Ligong Daxue Xuebao/Journal of East China University of Science and Technology*, 48(3), 343–351.
<https://doi.org/10.14135/j.cnki.1006-3080.20210128001>

Zhang Y, Joneurairatana E, & Vongphantuset J. (2024). An AI-Driven Decision Support Framework for Ergonomic

Optimization in Fashion Manufacturing: Integrating Predictive Analytics and MCDM Techniques. *Decision*

Making: Applications in Management and Engineering, 7(1), 786–802.
<https://doi.org/10.31181/dmame7120241449>

Zulfiqar L.R, Pamuji G.C, Saputra H, & Syawaludin F. (2024). Prediction of Raw Material Usage for Hijab Production Using k-Nearest Neighbors and Random Forest Methods. In *INCITEST 2024 - Proceedings of the 7th International Conference on Informatics, Engineering, Sciences and Technology*. Institute of Electrical and Electronics Engineers Inc.

<https://doi.org/10.1109/INCITEST64888.2024.11121429>

Anexos y elementos complementarios

Datos complementarios Additional information Dados complementares
No aplica
Financiamiento Financing Financiamento
No aplica
Informe de consentimiento Consent form Relatório de consentimento
No aplica
Uso de IA generativa Use of generative AI Uso de IA generativa
Uso genérico para mejora de la redacción
Conflicto de intereses Conflict of interest Conflito de interesses
No existen conflicto de interés entre los autores

El contenido de **Multidisciplinary Latin American Journal (ISSN: 2960-8414)**, publicados en este sitio están bajo una licencia de Creative Commons Attribution 4.0 International (CC BY 4.0). Los autores conservan los derechos morales y patrimoniales de sus obras. The contents of this article are under a Creative Commons Attribution 4.0 International (CC BY 4.0) license. The authors retain the moral and patrimonial rights of their works.

