



**Ciencia Latina**  
Internacional

---

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.  
ISSN 2707-2207 / ISSN 2707-2215 (en línea), noviembre-diciembre 2024,  
Volumen 8, Número 6.

[https://doi.org/10.37811/cl\\_rcm.v8i6](https://doi.org/10.37811/cl_rcm.v8i6)

**AUTOMATIZACIÓN Y MEJORA  
DE LA LOGÍSTICA EN BIENES DE CONSUMO  
CON ALGORITMOS DE APRENDIZAJE  
AUTOMÁTICO**

**AUTOMATION AND IMPROVEMENT OF LOGISTICS  
IN CONSUMER GOODS WITH MACHINE LEARNING  
ALGORITHMS**

**Dante Emanuel Tellez Guevara**  
Universidad Americana de Europa, México

DOI: [https://doi.org/10.37811/cl\\_rcm.v8i6.15062](https://doi.org/10.37811/cl_rcm.v8i6.15062)

## Automatización y Mejora de la Logística en Bienes de Consumo con Algoritmos de Aprendizaje Automático

**Dante Emanuel Tellez Guevara<sup>1</sup>**[dantetellez@yahoo.com](mailto:dantetellez@yahoo.com)<https://orcid.org/0009-0000-0458-4478>Universidad Americana de Europa  
México

### RESUMEN

La implementación de modelos de aprendizaje automático en la distribución de bienes de consumo es esencial para la optimización de procesos logísticos y la integración efectiva de la inteligencia artificial en entornos empresariales. Este estudio aborda la importancia de adoptar metodologías y marcos de trabajo adaptados a la madurez tecnológica, la estructura organizacional, el tamaño del equipo y la cultura corporativa de una empresa hipotética. El enfoque incluye desde la preparación de datos y el desarrollo de modelos predictivos hasta su integración práctica en sistemas logísticos. Superar las barreras organizacionales y técnicas es fundamental para garantizar la adopción exitosa de la IA en la logística. Este trabajo propone un enfoque integral que no solo evalúa la eficiencia técnica de los modelos de ML, sino también su alineación con las metas y estrategias empresariales. Aporta valor tanto al ámbito académico, con perspectivas teóricas y metodológicas, como al sector empresarial, proporcionando un marco práctico y adaptable para la implementación de soluciones de inteligencia artificial en un entorno logístico dinámico y competitivo.

**Palabras clave:** distribución, bienes de consumo, optimización logística, modelos predictivos

---

<sup>1</sup> Autor principal

Correspondencia: [dantetellez@yahoo.com](mailto:dantetellez@yahoo.com)

# Automation and Improvement of Logistics in Consumer Goods with Machine Learning Algorithms

## ABSTRACT

The implementation of machine learning models in consumer goods distribution is essential for optimizing logistics processes and effectively integrating artificial intelligence into business environments. This study addresses the importance of adopting methodologies and frameworks tailored to the technological maturity, organizational structure, team size, and corporate culture of a hypothetical company. The approach encompasses data preparation, the development of predictive models, and their practical integration into logistics systems. Overcoming organizational and technical barriers is crucial to ensure the successful adoption of AI in logistics. This work proposes a comprehensive approach that not only evaluates the technical efficiency of ML models but also ensures their alignment with business goals and strategies. It provides value to both the academic field, with theoretical and methodological perspectives, and the business sector, offering a practical and adaptable framework for implementing artificial intelligence solutions in a dynamic and competitive logistics environment.

**Keywords:** distribution, consumer goods, logistics optimization, predictive models

*Artículo recibido 02 octubre 2024*

*Aceptado para publicación: 12 noviembre 2024*



## INTRODUCCIÓN

En un contexto marcado por la transformación digital y la evolución constante de las tecnologías, las industrias enfrentan el desafío de modernizar y optimizar sus procesos para mantenerse competitivas (Valdés y Pérez 2020). En particular, el sector de distribución de bienes de consumo, que abarca desde la producción hasta la entrega de productos a los consumidores finales, ha experimentado avances significativos en los últimos años. Este sector desempeña un papel fundamental al garantizar la disponibilidad de una amplia gama de productos, como alimentos, electrodomésticos y ropa, en los puntos de venta y, finalmente, en manos de los consumidores (Rushton, et al 2022). En este entorno dinámico, las empresas enfrentan retos como la predicción precisa de la demanda, la mejora de la logística y la operación eficiente, factores críticos para asegurar el éxito en un mercado cada vez más competitivo.

El aprendizaje automático, o *Machine Learning* (ML), se ha consolidado como una herramienta clave para abordar estos desafíos debido a su capacidad para procesar grandes volúmenes de datos, identificar patrones complejos y generar predicciones precisas (Díaz-Ramírez 2021). Los modelos predictivos permiten optimizar la gestión de inventarios, planificar rutas de distribución de manera más eficiente y asignar recursos estratégicamente, lo que se traduce en beneficios como la reducción de costos operativos, la mejora del servicio al cliente y una ventaja competitiva en el mercado. Sin embargo, para maximizar el impacto de estas tecnologías, no basta con desarrollar modelos predictivos; es esencial garantizar su integración efectiva en las operaciones diarias (Kolltveit, et al 2022). Este proceso, conocido como operacionalización de modelos, consiste en trasladar los modelos desde su fase de desarrollo hasta su implementación en entornos de producción, asegurando su utilidad práctica y su capacidad para generar valor tangible.

Esta investigación valora modelos de aprendizaje automático con el objetivo de optimizar el sector de distribución de bienes de consumo. Además, evalúa estrategias para integrar y operacionalizar estos modelos, facilitando su aplicación en escenarios reales. Entre las tareas clave abordadas se encuentran la predicción de tiempos de transporte, y la optimización de rutas de distribución. Estas áreas de enfoque no solo buscan mejorar la eficiencia operativa, sino también proporcionar un marco adaptable para que las empresas del sector transformen la inteligencia analítica en resultados concretos y sostenibles.



A lo largo del trabajo, se analizarán también los pasos necesarios para superar las barreras organizacionales y técnicas en la implementación de modelos de ML. Esto incluye una evaluación inicial de la preparación tecnológica y organizativa, el desarrollo de una estrategia clara para la integración de datos y software, y la implementación efectiva de los modelos, asegurando su monitoreo y mantenimiento continuo. De esta forma, el estudio busca contribuir al avance en la aplicación práctica de la inteligencia artificial en la logística y distribución, proporcionando tanto una base teórica como una guía práctica para su implementación exitosa.

### **Contribución principal**

La principal contribución de este trabajo es el desarrollo de una metodología integral para la operacionalización eficiente de modelos predictivos en el sector de distribución de bienes de consumo. Esta metodología tiene como objetivo principal facilitar la integración efectiva de modelos de ML en entornos de producción empresarial, abordando los desafíos técnicos y organizativos que acompañan este proceso.

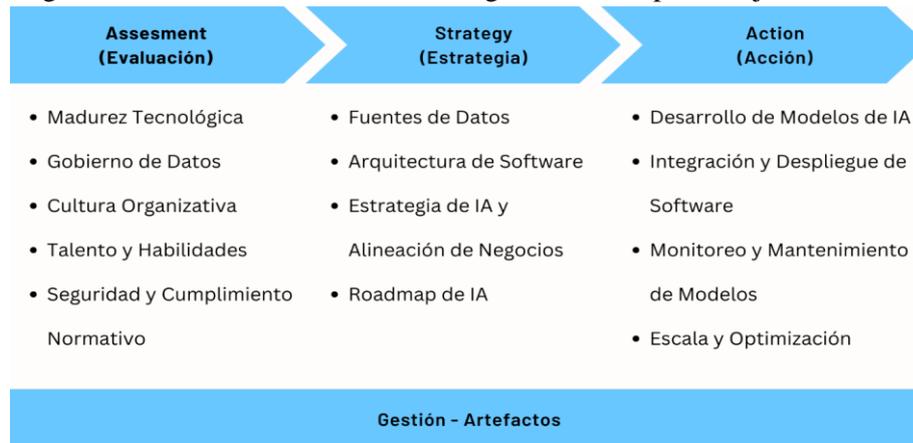
El enfoque propuesto incluye:

1. Predicción de tiempos de transporte mediante algoritmos que permiten una planificación logística más precisa y mejoran la satisfacción del cliente.
2. Optimización de rutas de distribución a través de técnicas que analizan patrones históricos y actuales para reducir costos operativos, tiempos de entrega e impacto ambiental.

### **Justificación**

La implementación adecuada de técnicas de aprendizaje automático, no solo desde el punto de vista técnico, sino también organizacional, tiene un gran potencial para transformar la eficiencia operativa en los procesos logísticos de distribución de bienes de consumo. Al aplicar estos modelos en áreas clave como la predicción de tiempos de transporte, la optimización de rutas y la toma de decisiones estratégicas en marketing, las empresas pueden mejorar no solo su rendimiento operativo, sino también adaptarse mejor a las necesidades cambiantes del mercado y los consumidores.

**Figura 1.** Marco para la operacionalización de modelos de ML en la Automatización y Mejora de la Logística en Bienes de Consumo con Algoritmos de Aprendizaje Automático.



*Notas:* El proceso comienza con la evaluación, que se enfoca en analizar la preparación tecnológica y organizacional. A continuación, en la fase de estrategia, se define un plan de datos y software para alinear la IA con los objetivos empresariales. Finalmente, en la etapa de acción, se trabaja en el desarrollo y mantenimiento continuo de los modelos de IA.

Fuente: Elaboración propia.

El uso de modelos de ML permite procesar grandes volúmenes de datos rápidamente, identificando patrones ocultos que facilitan la toma de decisiones informadas en tiempo real. Sin embargo, para que estos beneficios sean plenamente aprovechados, es necesario un despliegue efectivo de los modelos, asegurando su integración adecuada en los sistemas existentes y su monitoreo continuo.

Desde una perspectiva económica, la optimización de rutas mediante ML puede generar ahorros significativos en costos operativos. A nivel ambiental, la mejora en la eficiencia logística contribuye a la reducción de emisiones de carbono, alineándose con las regulaciones medioambientales y fortaleciendo la responsabilidad corporativa. Además, la gestión más eficiente de la cadena de suministro, derivada de la aplicación de estos modelos, puede ayudar a las empresas a cumplir con normativas ambientales y mejorar su imagen ante los consumidores.

## METODOLOGÍA

Esta sección describe la metodología propuesta para la operacionalización eficiente de modelos predictivos en el sector de distribución de bienes de consumo. Esta metodología, mostrada en la Figura 1, se basa en tres pilares fundamentales: i) Evaluación; ii) Estrategia; y iii) Acción, que permiten una implementación efectiva de los modelos de aprendizaje automático en la logística.

El primer pilar, Evaluación, destaca la importancia de la madurez tecnológica en la industria de distribución. Los proyectos de predicción de tiempos de transporte y optimización de rutas requieren

sistemas avanzados capaces de procesar grandes volúmenes de datos y ejecutar algoritmos de aprendizaje automático de manera eficiente. Mantenerse al día con las últimas tendencias tecnológicas es crucial para asegurar la competitividad. Además, la gestión adecuada de los datos es esencial para la precisión de los modelos. Un gobierno de datos robusto implica establecer políticas claras para la recopilación, almacenamiento y uso seguro de la información, garantizando la calidad y el cumplimiento con las regulaciones de protección de datos. La implementación exitosa también depende de un cambio cultural dentro de la organización, promoviendo una cultura de innovación, aprendizaje continuo y colaboración entre los equipos de logística, tecnología y datos. Otro factor clave es contar con el talento adecuado. Es imprescindible tener expertos en análisis de datos, aprendizaje automático y logística, quienes, a través de equipos multidisciplinarios, combinan conocimientos técnicos con experiencia en la industria. Finalmente, la seguridad y el cumplimiento normativo son fundamentales en todo el proceso, asegurando la protección de los datos y el cumplimiento con las normativas del sector, como las relativas a la seguridad de la cadena de suministro.

El segundo pilar, Estrategia, se centra en la identificación y gestión de las fuentes de datos necesarias para los proyectos de predicción y optimización. Es esencial recopilar datos en tiempo real, como el seguimiento de pedidos, información de almacenes y datos de inventarios, para garantizar que los modelos se mantengan actualizados y precisos. Además, la arquitectura de software debe ser escalable y flexible, permitiendo manejar grandes volúmenes de datos y ejecutar algoritmos de aprendizaje automático de manera eficiente. Debe integrarse con los sistemas existentes y permitir futuras expansiones. Un ejemplo de arquitectura efectiva para estos proyectos podría involucrar la ingesta de datos a través de Amazon S3, el uso de AWS Glue para el procesamiento de datos, y el despliegue de modelos mediante AWS Lambda, con monitoreo a través de Amazon CloudWatch. La estrategia de inteligencia artificial debe estar alineada con los objetivos comerciales de la empresa, como la reducción de costos y la mejora de la eficiencia operativa. Es fundamental definir cómo los modelos de IA contribuirán a estos objetivos y cómo se medirá su impacto en el negocio. Además, el establecimiento de un roadmap de IA es esencial para planificar la implementación de proyectos a lo largo del tiempo, con hitos claros para el desarrollo, las pruebas, el despliegue y la monitorización continua de los modelos.



El último pilar, Acción, se refiere al desarrollo de modelos de IA robustos. Esto incluye la selección de los algoritmos más adecuados, la preparación y el entrenamiento de los datos, y la evaluación de los modelos para garantizar que generen predicciones precisas que faciliten la toma de decisiones en la distribución de bienes de consumo. La acción efectiva implica que todos estos procesos se lleven a cabo de manera eficiente y alineada con los objetivos estratégicos de la empresa. Como ejemplo de modelos se describen a continuación, el modelo para la predicción del tiempo de transporte, y posteriormente el modelo para la optimización de rutas.

### **A. Predicción del tiempo de transporte**

En el ámbito de la logística, los modelos predictivos de tiempo de transporte buscan estimar la duración del envío de bienes entre dos ubicaciones. Este tiempo es un factor clave en la planificación de envíos y puede verse influido por múltiples variables. Comprender estos factores es fundamental para el desarrollo de modelos predictivos efectivos y precisos en este campo (Tang, et al 2020; Akbari y Do 2021).

Para realizar estas predicciones, se emplean diferentes métodos de regresión, como la Regresión Lineal (James, et al, 2023) y la Regresión No Lineal (Suzuki, 2020), así como modelos basados en árboles, como Random Forest (Liaw, et al, 2002) y Gradient Boosting (Fafalios, et al, 2020), además de técnicas de aprendizaje profundo como las Redes Neuronales (Matsuo, et al, 2022). La elección del método adecuado depende de las características de los datos y de la naturaleza de la relación entre las variables de entrada y el tiempo de transporte (Song y Dong, 2021; Satheesh y Kumar, 2022).

El desarrollo de un modelo predictivo comienza con la recolección y el procesamiento de los datos relevantes. La calidad de estos datos es crucial, ya que determina la precisión de las predicciones. Una vez que los datos están listos, se selecciona el modelo más adecuado según las características del conjunto de datos y el tipo de predicción deseada. Posteriormente, el modelo se entrena utilizando los datos disponibles, ajustándose para identificar patrones y relaciones que reflejan el comportamiento de los datos.

La validación del modelo es un paso esencial para asegurar su efectividad. Una técnica comúnmente utilizada es la validación cruzada (Satheesh y Kumar, 2022), en la que se divide el conjunto de datos en varias partes y el modelo se entrena y prueba en diferentes segmentos.



Este enfoque ayuda a evaluar la capacidad del modelo para generalizar y no limitarse a los datos con los que fue entrenado.

La evaluación del desempeño del modelo se realiza mediante diversas métricas, siendo una de las más utilizadas el Error Cuadrático Medio (MSE) (Shcherbakov, et al, 2013). Después de la validación, el modelo se ajusta según sea necesario para optimizar su rendimiento antes de ser implementado para hacer predicciones en escenarios del mundo real. Esta fase de implementación es crucial en áreas como la logística y la planificación de rutas, donde la precisión de las predicciones del tiempo de transporte es fundamental para la toma de decisiones estratégicas. Además, en el contexto de este proyecto, también se explorará el Modelo de Ruta Óptima, que se detallará a continuación.

## **B. Optimización de rutas de distribución**

La optimización de rutas es un aspecto fundamental en la planificación logística, cuyo objetivo principal es reducir al mínimo el tiempo necesario para transportar bienes entre varios puntos. El propósito de este proceso es identificar la mejor secuencia de paradas para garantizar que el tiempo total de transporte sea el más bajo posible. Para desarrollar un modelo de ruta óptima, se deben considerar ciertos supuestos y simplificaciones:

1. **Tiempos de transporte conocidos:** Se parte de la premisa de que los tiempos de traslado entre los diferentes puntos de la red son conocidos y precisos. Esto permite construir una matriz que refleje los tiempos de viaje entre todos los posibles pares de puntos.
2. **Enfoque simplificado:** El modelo se centra exclusivamente en encontrar las rutas más eficientes entre los puntos de origen y destino, sin tener en cuenta detalles específicos de los pedidos, como el tipo de carga o la cantidad a transportar.

Para resolver este problema, se pueden aplicar técnicas matemáticas de optimización, como la programación lineal, o utilizar algoritmos específicos como el de Dijkstra, que es útil para encontrar el camino más corto en una red de conexiones.

El objetivo del modelo es, por tanto, minimizar el tiempo total de transporte. Se busca que el sistema seleccione la ruta más rápida entre todos los puntos, garantizando que cada punto sea visitado solo una vez y que la ruta sea continua, regresando al punto de inicio una vez que todos los destinos hayan sido alcanzados.



## RESULTADOS Y DISCUSIÓN

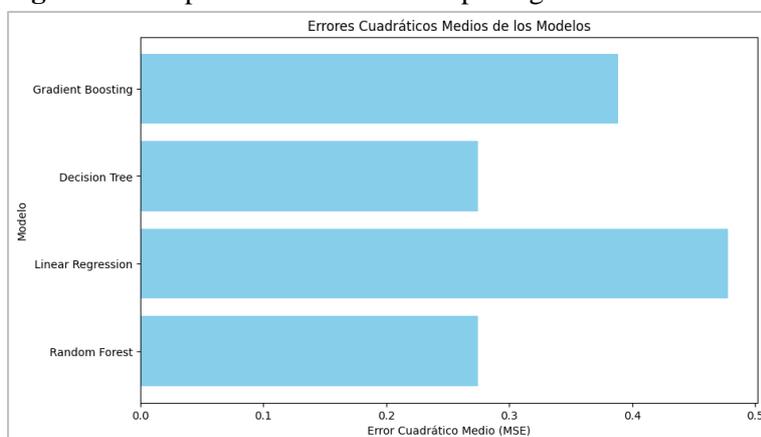
Esta sección está dedicada a presentar los resultados obtenidos durante la implementación de los modelos predictivos para la mejora de la logística en el sector de distribución de bienes de consumo. A través del uso de algoritmos de aprendizaje automático, se contribuye significativamente a la automatización y optimización de los procesos logísticos, permitiendo una mejor toma de decisiones en la cadena de suministro.

### A. Predicción de los Tiempos de Transporte

Los resultados del modelo para la predicción del tiempo de transporte se muestran en la Figura 2. La predicción de los tiempos de transporte es un componente esencial para mejorar la eficiencia en la logística de bienes de consumo. Diversos modelos fueron evaluados con el objetivo de identificar el más adecuado para predecir los tiempos de entrega y mejorar la planificación de la distribución.

El modelo de Random Forest destacó por su rendimiento, alcanzando un MSE de 0.275, lo que se traduce en un error promedio de 6.6 horas. Este modelo mostró ser especialmente efectivo debido a su capacidad para manejar grandes volúmenes de datos y características complejas, sin necesidad de ajustes extensivos, lo que es clave para la operacionalización eficiente en entornos logísticos dinámicos. En comparación, el modelo de regresión lineal presentó un MSE de 0.478 (11.47 horas), lo que refleja una menor capacidad para capturar relaciones no lineales. Aunque más sencillo y comprensible, su rendimiento se ve limitado en entornos complejos como el de la logística, donde las variables no siguen patrones lineales simples.

**Figura 2.** Comparación de error MSE por algoritmo.



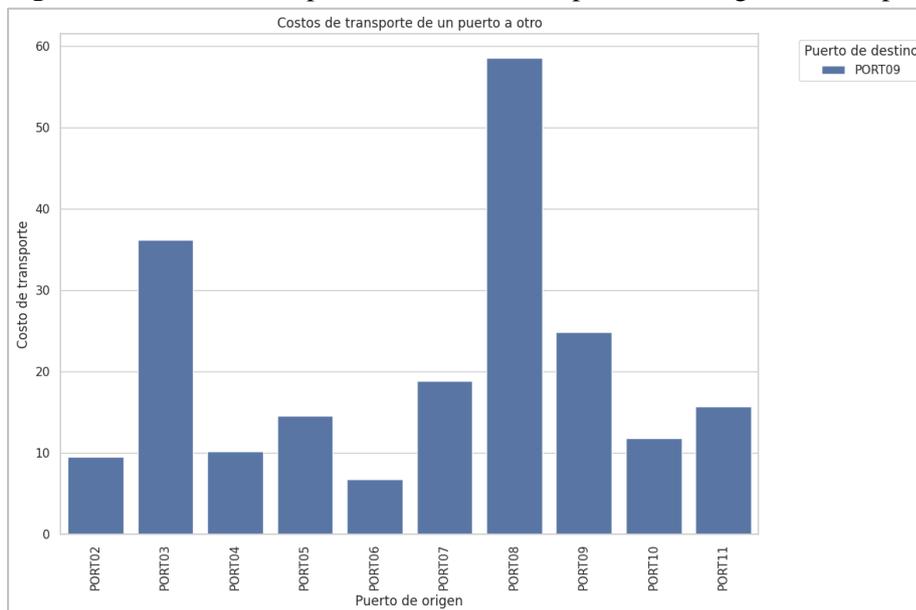
Notas: El modelo de Random Forest y el árbol de decisión presentan los valores más bajos de MSE, seguidos por Gradient Boosting y la regresión lineal, que muestra un rendimiento superior en términos de error respecto a los otros modelos.

Fuente: Elaboración propia.

Por otro lado, el modelo de árbol de decisión obtuvo resultados similares a los de Random Forest, con un MSE cercano a 0.275, lo que demuestra su eficacia para manejar datos tanto numéricos como categóricos. Este tipo de modelo es especialmente útil en la predicción de tiempos de transporte, ya que es fácil de interpretar y proporciona una visualización clara de las decisiones tomadas.

El modelo de Gradient Boosting logró un MSE de 0.389 (9.33 horas), lo que indica un desempeño algo inferior, pero sigue siendo valioso en escenarios más complejos debido a su capacidad de iterar y corregir errores, mejorando gradualmente la precisión del modelo a medida que se ajustan los parámetros.

**Figura 3.** Costos de transporte desde diferentes puertos de origen hacia el puerto de destino 'PORT09'.



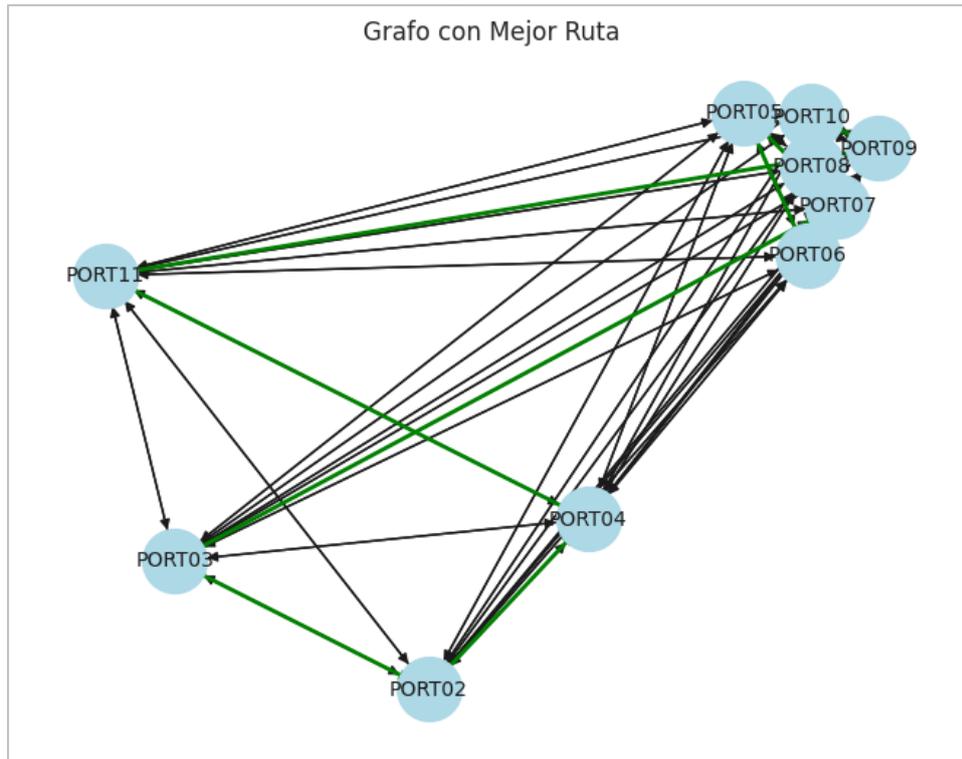
Notas: La gráfica muestra los costos de transporte en función de los valores calculados entre cada puerto de origen (PORT02, PORT03, PORT04, etc.) y el puerto de destino 'PORT09'. Se puede observar que los costos varían considerablemente, con el puerto de origen 'PORT08' mostrando el costo más alto de 58.55, mientras que el puerto 'PORT06' presenta el costo más bajo de 6.77. Estos datos proporcionan una visión útil para la toma de decisiones logísticas, permitiendo seleccionar rutas de bajo costo y optimizar la cadena de suministro.

Fuente: Elaboración propia.

## B. Optimización de Rutas

La optimización de rutas constituye un aspecto crucial para la mejora de la logística en la distribución de bienes de consumo. En este estudio, los tiempos de transporte se utilizaron para construir una matriz de distancias o tiempos entre los puertos involucrados, facilitando la identificación de las rutas más eficientes.

**Figura 4.** Resultados del modelo de optimización de rutas



Notas: Ruta encontrada: Mejor ruta que conecta los puertos en el siguiente orden: ['PORT08', 'PORT06', 'PORT05', 'PORT07', 'PORT03', 'PORT02', 'PORT04', 'PORT11', 'PORT09', 'PORT10', 'PORT08']. Esta ruta fue optimizada utilizando un algoritmo de optimización de rutas (TSP, Problema del Viajante de Comercio), donde el objetivo era minimizar el tiempo de transporte entre los puertos. La ruta se muestra en verde sobre el grafo.

Fuente: Elaboración propia.

En esta fase, se omitieron los detalles específicos de los pedidos individuales para centrarse exclusivamente en la logística del transporte entre puertos, lo que simplificó el modelo y permitió una optimización más efectiva. El objetivo principal fue minimizar el tiempo total de transporte, reduciendo costos y aumentando la eficiencia general de la cadena de suministro.

Se utilizó OR-Tools (Google, s.f.), un paquete de software de código abierto desarrollado por Google, para realizar la optimización de rutas. Este software es adecuado para resolver problemas complejos en el enrutamiento de vehículos y la programación de restricciones. Al aplicar OR-Tools, se identificaron las rutas más rápidas y económicas entre los puertos, lo que puede generar importantes ahorros en costos logísticos y tiempos de entrega.

En la Figura 3 se ilustran los costos de transporte desde varios puertos hacia el puerto de destino 'PORT09'. Los valores de los costos proporcionan una visión general útil para la toma de decisiones logísticas, mostrando claramente las diferencias en los costos de transporte según el puerto de origen. Con esta información, es posible optimizar la cadena de suministro, tomando decisiones informadas

que reduzcan los costos operativos y mejoren la eficiencia del sistema logístico en su conjunto. Además, en la Figura 4 se muestra la mejor ruta optimizada, la cual conecta una serie de puertos de origen con el puerto de destino de manera eficiente, minimizando el tiempo total de transporte. La ruta óptima es el resultado de un análisis detallado del problema del Viajante de Comercio (TSP), y su visualización es crucial para comprender cómo las decisiones sobre la secuencia de los puertos pueden impactar en la eficiencia global de la logística. Al combinar los datos de la Figura 2 con la ruta optimizada de la Figura 3, se obtiene una visión completa que facilita la toma de decisiones estratégicas para mejorar la operación del sistema logístico, reducir costos y aumentar la competitividad en el mercado.

## CONCLUSIONES

La implementación de modelos de aprendizaje automático en la distribución de bienes de consumo demuestra ser una estrategia clave para la optimización de procesos logísticos, contribuyendo significativamente a la eficiencia operativa en la cadena de suministro. Este estudio ha subrayado la importancia de desarrollar metodologías adaptadas a las características particulares de cada organización, considerando factores como la madurez tecnológica, la estructura organizacional y la cultura corporativa. Estas variables son determinantes para garantizar la integración efectiva de la inteligencia artificial en los sistemas logísticos, lo que puede traducirse en ventajas competitivas sostenibles.

Los resultados obtenidos de los modelos predictivos de predicción de tiempos de transporte y optimización de rutas validan la capacidad de los algoritmos de aprendizaje automático para mejorar la toma de decisiones logísticas. Modelos como Random Forest y los árboles de decisión demostraron ser efectivos para manejar grandes volúmenes de datos, capturando relaciones no lineales que impactan directamente en la precisión de las predicciones. A su vez, la optimización de rutas a través de algoritmos como OR-Tools refleja cómo la inteligencia artificial puede reducir costos operativos y mejorar la eficiencia en la distribución de bienes, adaptándose a escenarios dinámicos y cambiantes.

Sin embargo, la implementación exitosa de estas soluciones no solo depende de la eficiencia técnica de los modelos, sino también de su integración práctica dentro del marco organizacional.

Es necesario superar diversas barreras, tanto tecnológicas como culturales, que pueden obstaculizar la adopción de la IA en entornos logísticos. La resistencia al cambio, la falta de capacitación y la



complejidad de los sistemas heredados son factores que deben ser considerados al implementar soluciones de IA.

Este trabajo propone un enfoque integral que no solo evalúa el rendimiento de los modelos de ML, sino que también examina su alineación con los objetivos estratégicos y las metas empresariales. Al proporcionar un marco práctico y adaptable, este estudio aporta valor tanto al ámbito académico, al ofrecer nuevas perspectivas metodológicas, como al sector empresarial, brindando una guía para la adopción de la IA en un contexto logístico altamente competitivo y en constante evolución.

## REFERENCIAS BIBLIOGRAFICAS

- Akbari, M., & Do, T. N. A. (2021). A systematic review of machine learning in logistics and supply chain management: Current trends and future directions. *Benchmarking: An International Journal*, 28(10), 2977-3005.
- Díaz-Ramírez, J. (2021). Aprendizaje automático y aprendizaje profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181.
- Fafalios, S., Charonyktakis, P., & Tsamardinos, I. (2020). *Gradient boosting trees* (pp. 1-3). Gnosis Data Analysis PC.
- Google. (s.f.). OR-Tools. Google. <https://developers.google.com/optimization?hl=es-419>
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python* (pp. 69-134). Springer.
- Kolltveit, A. B., & Li, J. (2022, May). Operationalizing machine learning models: A systematic literature review. In *Proceedings of the 1st Workshop on Software Engineering for Responsible AI* (pp. 1-8).
- Liaw, A., Wiener, M., et al. (2002). Classification and regression by randomForest. *R News*, 2(3), 18-22.
- Matsuo, Y., et al. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267-275.
- Rushton, A., Croucher, P., & Baker, P. (2022). *The handbook of logistics and distribution management: Understanding the supply chain*. Kogan Page Publishers.



- Satheesh, M. K., & Kumar, K. V. R. (2022). Addressing the utilization of popular regression models in business applications. In *Machine learning for business analytics* (pp. 29-43). Productivity Press.
- Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., Tyukov, A. P., Janovsky, T. A., Kamaev, V. A., et al. (2013). A survey of forecast error measures. *World Applied Sciences Journal*, 24(24), 171-176.
- Song, X., & Dong, J. (2021). A dynamic pricing and inventory model for retail chains with online and offline sales channels. *European Journal of Operational Research*, 290(3), 915-927.
- Suzuki, J. (2020). *Statistical learning with math and R: 100 exercises for building logic* (pp. 117-146). Springer.
- Tang, J., Zheng, L., Han, C., Yin, W., Zhang, Y., Zou, Y., & Huang, H. (2020). Statistical and machine-learning methods for clearance time prediction of road incidents: A methodology review. *Analytic Methods in Accident Research*, 27, 100123.
- Valdés Figueroa, L., & Pérez, G. (2020). Transformación digital en la logística de América Latina y el Caribe.

