

Artificial intelligence-based proposal to optimize logistics processes in the commercial sector in northern Peru

Andrew Gabriel, Balarezo Zelada¹, Fatima Alexandra, Granda Pretel², and Jean Carlos, Escurra-Lagos³

^{1,2}Private University of the North, Peru, N00207169@0upn.pe, N00259058@upn.pe

³Private University of the North, Peru, jean.escurra@upn.edu.pe

Abstract– *This article presents the design of a prototype system based on artificial intelligence aimed at optimizing logistics processes in the commercial sector of Trujillo, Peru. The proposed architecture includes predictive modules and a conversational interface (chatbot) to address common issues such as stockouts, overstocking, and empirical decision-making. The system conceptually applies mathematical models for demand forecasting and automated recommendations. Key data sources were identified, performance metrics were defined, and a cost structure feasible for small and medium-sized enterprises was estimated. The results show that the prototype system could be a solution that contributes to significantly improving operational efficiency, reducing logistical errors, and facilitating data-driven decision-making. The conclusions confirm the applicability of the system in regional digital transformation efforts, demonstrating its potential to enhance commercial competitiveness through accessible, scalable, and context-aware technological solutions.*

Keywords: *Artificial intelligence, logistics processes, chatbot, commercial sector*

Propuesta basada en inteligencia artificial para optimizar los procesos logísticos del sector comercial en el norte del Perú

Andrew Gabriel, Balarezo Zelada¹, Fatima Alexandra, Granda Pretel², y Jean Carlos, Ecurra-Lagos³

^{1,2}Universidad Privada del Norte, Perú, N00207169@upn.pe, N00259058@upn.pe

³Universidad Privada del Norte, Perú, jean.escurra@upn.edu.pe

Resumen– El presente artículo expone el diseño de un prototipo de sistema basado en inteligencia artificial orientado a optimizar los procesos logísticos del sector comercial en Trujillo, Perú. A través de una arquitectura conceptual compuesta por módulos predictivos e interfaz conversacional, se busca responder a problemáticas comunes como quiebres de stock, sobreabastecimientos y decisiones empíricas. La propuesta contempla modelos matemáticos para la previsión de demanda y recomendaciones automatizadas mediante chatbot. Se identificaron fuentes de datos clave, se definieron métricas de evaluación y se estimó una estructura de costos viable para pymes. Los resultados reflejan que el prototipo del sistema puede ser una solución que contribuya a mejorar significativamente la eficiencia operativa, reducir errores logísticos y facilitar la toma de decisiones basada en datos. Las conclusiones destacan la aplicabilidad del sistema en contextos de transformación digital local, demostrando su potencial para fortalecer la competitividad comercial mediante soluciones tecnológicas accesibles, escalables y alineadas con la realidad del entorno.

Palabras clave: Inteligencia artificial, procesos logísticos, chatbot, sector comercial.

I. INTRODUCCIÓN

Durante los últimos años, la inteligencia artificial (IA) ha comenzado a redefinir los procesos logísticos en distintos sectores, especialmente en el ámbito comercial, ofreciendo soluciones que permiten prever la demanda, automatizar la gestión de inventarios y optimizar rutas de distribución en tiempo real.

La creciente complejidad de las cadenas de suministro globales ha impulsado el uso del aprendizaje automático para enfrentar desafíos como interrupciones y escasez de materiales [1]. Herramientas como la Planificación Probabilística Generativa (PPG) están revolucionando la toma de decisiones al adaptarse a objetivos cambiantes y demandas inciertas [2]. La IA y el Aprendizaje Automático son esenciales para optimizar la previsión de demanda, el inventario, el transporte y la selección de proveedores [3], así como para fomentar la logística sostenible mediante la reducción de emisiones y residuos [4]. En el contexto del comercio electrónico, estas tecnologías automatizan decisiones clave y mejoran la eficiencia operativa [5]. Además, están transformando las cadenas tradicionales en sistemas adaptativos con mayor precisión en la planificación [6]. El análisis predictivo, apoyado en grandes volúmenes de datos, permite anticipar tendencias e interrupciones [7], mientras que los algoritmos de aprendizaje por refuerzo profundo optimizan el enrutamiento en escenarios

complejos, como con vehículos eléctricos [8] y multivehículo [9], reduciendo costos y mejorando la eficiencia [10]. También se ha aplicado con éxito en la cadena de frío, reduciendo costos operativos [11], y en la contratación de transporte tercerizado mediante algoritmos heurísticos basados en ML [12]. La combinación de IA e IoT optimiza rutas logísticas [13], mientras que modelos híbridos como QAmplifyNet muestran un alto rendimiento en la predicción de pedidos [14]. Finalmente, en contextos de logística de emergencia, la IA ha permitido optimizar rutas con significativas reducciones de costos [15].

La inteligencia artificial y el aprendizaje automático están transformando la gestión de inventarios al mejorar la previsión de demanda, optimizar asignaciones y reducir costos en sectores como el retail, la industria y las cadenas complejas [16], [17], [18], [19]. Aplicaciones en almacenes inteligentes, pymes y entornos industriales han incrementado la eficiencia y reducido pérdidas [20], [21], [22]. El aprendizaje por refuerzo y los modelos DRL permiten mayor resiliencia y adaptación, incluso sin supuestos rígidos [23], [24], [25], [26], superando estrategias clásicas como la política (s, Q) en escenarios estacionales [27]. También se destacan políticas más resilientes frente a entornos cambiantes [28], y mejoras en entornos multinivel [29]. Algoritmos como MCTS eliminan el efecto látigo [30], y tecnologías como big data, apps móviles, códigos de barras, UAV y blockchain fortalecen la trazabilidad y reducen costos [31], [32]. Nuevos enfoques como el Aprendizaje Controlado Profundo y LLM como agentes autónomos fortalecen la toma de decisiones en sistemas dinámicos [33], [34]. Modelos inspirados en RNN, agentes inteligentes y marcos como A2C permiten gestionar miles de productos y sincronizar flujos logísticos a gran escala [35], [36], [37], [38]. Además, el aprendizaje Q profundo y el enfoque multiagente optimizan cadenas globales [39], [40]. En sectores como FMCG y automotriz, la IA mejora el reabastecimiento y el punto de equilibrio [41], [42], mientras que su integración en ERP mejora la previsión [43]. Herramientas como visión artificial, algoritmos de agrupamiento y planificación con IA generan ahorros y aumentan precisión y satisfacción del cliente [44], [45], [46]. En salud, el caso del huracán Helene reveló fallas logísticas que motivaron el uso de IA para equilibrar inventarios [47]. A pesar de su potencial, persisten barreras como baja adopción, temores por despidos y limitaciones técnicas en pymes [48], aunque se reconoce su impacto positivo en eficiencia, precisión y toma de decisiones.

En el Perú, la inteligencia artificial (IA) se encuentra en una fase de desarrollo, aunque limitada por factores como la brecha digital y la escasa formación especializada [49]. Su uso ya se extiende al ámbito empresarial, facilitando tareas como la investigación y redacción académica [50], y comienza a impactar sectores clave como la minería, el comercio electrónico y la salud, generando tanto oportunidades como riesgos laborales [51]. Iniciativas de gran escala, como el Megapuerto de Chancay, integran la IA para optimizar la logística y reforzar la competitividad comercial del país. Asimismo, la tecnología está mejorando procesos como el control interno y la gestión de inventarios, al aumentar la eficiencia operativa y prevenir fraudes [52]. En el ámbito agrícola, se han aplicado modelos de aprendizaje automático, como LSTM, para predecir con éxito las importaciones mensuales de productos vegetales [53].

A nivel local, especialmente en el norte del Perú, hay poca investigación sobre el uso de IA en los procesos logísticos del sector comercial. Sin embargo, su aplicabilidad ha sido validada en otros ámbitos, como en la Universidad Nacional de Trujillo con un chatbot para servicios estudiantiles [54] y con la creación de una dispensadora automática de bebidas en un proyecto universitario [55]. A pesar de estos avances, en ciudades como Trujillo, la gestión de inventarios aún se basa en métodos manuales y decisiones empíricas, generando errores, pérdidas y baja capacidad de anticipación. Esta limitada adopción tecnológica afecta la competitividad, por lo que el presente estudio busca analizar el impacto de la IA en los procesos logísticos comerciales de la región, aportando evidencia para impulsar la transformación digital en este contexto.

II. ESTADO DEL ARTE

A. Inteligencia Artificial

La inteligencia artificial moderna se basa en enfoques ascendentes, donde sistemas complejos se construyen a partir de componentes simples que aprenden y se desarrollan con el tiempo. Entre las técnicas más destacadas se encuentran las redes neuronales artificiales, los algoritmos genéticos y la computación evolutiva [56].

B. Aprendizaje Automático

El aprendizaje automático busca que las computadoras realicen tareas complejas sin que sea necesario programar cada paso. Parte de modelos generales con múltiples parámetros que se ajustan automáticamente mediante datos de entrenamiento. Así, el sistema aprende patrones y genera un modelo especializado capaz de realizar tareas como reconocer imágenes, jugar ajedrez o conducir [57].

C. Algoritmos de aprendizaje

Un algoritmo de aprendizaje automático es capaz de mejorar su desempeño mediante la experiencia. Estos algoritmos se diseñan para adaptar su comportamiento con base en datos, ajustando sus parámetros internos para optimizar su rendimiento en tareas específicas. Existen diversas combinaciones de tareas, métricas de evaluación y tipos de experiencia que determinan cómo y qué aprende el sistema [58].

D. Planificación Automatizada

La planificación de acciones es fundamental para los agentes inteligentes. Este campo se basa en representaciones factorizadas de estados y acciones que permiten modelar de manera eficiente diversos dominios sin depender de heurísticas específicas. Los avances incluyen algoritmos eficientes de planificación, el uso de acciones jerárquicas para abordar problemas complejos, y la extensión a entornos parcialmente observables o no deterministas [59].

La literatura internacional evidencia avances relevantes en el uso de inteligencia artificial para la gestión predictiva de inventarios. Estudios muestran que el aprendizaje automático mejora la precisión en la previsión de demanda y optimiza el reabastecimiento automático [60]. Modelos como Random Forest, XGBoost y LSTM han logrado mejoras del 20 % en precisión y reducciones del 15 % en costos de inventario [61]. Además, los frameworks de aprendizaje por refuerzo multiagente demuestran alta eficiencia para enfrentar demandas variables [62], y modelos combinados en forecasting probabilístico superan enfoques tradicionales en demandas intermitentes [63]. Finalmente, sistemas semi-automatizados con IA permiten monitoreo en tiempo real y reducen desabastecimientos [64]. Estos antecedentes respaldan la viabilidad de un aplicativo predictivo en el sector comercial del norte del Perú.

III. OBJETIVOS

A. Objetivo General

Diseñar un prototipo de sistema basado en inteligencia artificial orientado a optimizar los procesos logísticos del sector comercial en el norte del Perú, Trujillo 2025.

B. Objetivo (s) Específico (s)

- Definir la arquitectura conceptual del sistema de Inteligencia artificial del sector comercial en el norte del Perú, Trujillo 2025.
- Identificar las fuentes de datos y requisitos clave para el sistema de inteligencia artificial del sector comercial en el norte del Perú, Trujillo 2025.
- Proponer los modelos de Inteligencia artificial y la lógica de interacción del chatbot, del sector comercial en el norte del Perú, Trujillo 2025.
- Definir métricas de evaluación del sistema de Inteligencia artificial del sector comercial en el norte del Perú, Trujillo 2025.

IV. METODOLOGÍA

La presente investigación, de enfoque tecnológico y tipo proyectivo, propone el diseño de una solución basada en inteligencia artificial para optimizar los procesos logísticos en el sector comercial del norte del Perú. Esta propuesta conceptual, sin implementación en esta etapa, se contextualiza en una problemática empresarial real, siguiendo la premisa de que el diseño de sistemas de IA requiere un enfoque iterativo y una validación conceptual temprana para asegurar su pertinencia y viabilidad. El estudio analiza cómo la IA puede afrontar las limitaciones logísticas comunes en las

pymes mediante el procesamiento automatizado de datos, alertas predictivas y recomendaciones, priorizando la interpretabilidad de los modelos para facilitar la toma de decisiones [65]. La propuesta incluye tres módulos principales: ingreso de datos, motor de IA y un chatbot como interfaz de usuario. La conceptualización de la arquitectura de datos es fundamental para definir la recolección y preprocesamiento [66]. El chatbot se diseña para facilitar el uso por personal no técnico, priorizando claridad y eficiencia en interacciones complejas [67]. Finalmente, se ha desarrollado un modelo de arquitectura tecnológica que representa la interacción entre los módulos, sirviendo como base para futuras etapas de desarrollo o validación empírica, tal como se muestra en la Figura 1:




Fig. 1 Arquitectura del sistema propuesto

La validación funcional del prototipo se sustenta en la aplicación conceptual de modelos matemáticos y algorítmicos subyacentes que el Motor de IA emplearía para sus predicciones y recomendaciones. La arquitectura está diseñada para implementar los siguientes principios:

- Predicción de Demanda (Dt): La base para la gestión de inventario es la estimación de la demanda futura. Conceptualizamos el uso de modelos de series de tiempo, como el suavizado exponencial simple, para predecir la demanda en un período t .

Suavizado Exponencial Simple (SES): [68]

$$F_{t+1} = \alpha A_t + (1 - \alpha) F_t \quad (1)$$

Donde F_{t+1} es el pronóstico para el siguiente período, A_t es la demanda real del período actual, F_t es el pronóstico del período actual y α es el factor de suavizado ($0 \leq \alpha \leq 1$). Este modelo se usaría para identificar patrones de consumo y

proyectar tendencias.

- Cálculo del Punto de Reorden (ROP): Para determinar cuándo realizar un pedido de reabastecimiento, el sistema conceptualmente calcularía el Punto de Reorden, que considera la demanda durante el tiempo de entrega y un margen de seguridad: [69]

$$ROP = (D_{prom} \times LT) + SS \quad (2)$$

Donde D_{prom} es la demanda promedio diaria (o por período), LT es el tiempo de entrega del proveedor y SS es el stock de seguridad.

- Cálculo del Stock de Seguridad (SS): El stock de seguridad es vital para mitigar la incertidumbre en la demanda y el tiempo de entrega. Conceptualizamos su cálculo basado en la variabilidad de la demanda y el nivel de servicio deseado: [70]

$$SS = Z \times \sigma_D \times \sqrt{LT} \quad (3)$$

Donde Z es el factor Z (obtenido de la tabla de distribución normal estándar para un nivel de servicio deseado), σ_D es la desviación estándar de la demanda diaria y LT es el tiempo de entrega. Este componente es crucial para las alertas de quiebre de stock.

- Optimización de Cantidad de Pedido (EOQ - Cantidad Económica de Pedido): Aunque no se genera directamente en las respuestas del chatbot, el motor de IA podría conceptualmente utilizar el EOQ para recomendar volúmenes de pedido que minimicen los costos totales de inventario: [71]

$$EOQ = \sqrt{\frac{2DS}{H}} \quad (4)$$

Donde D es la demanda anual, S es el costo de realizar un pedido y H es el costo de mantener una unidad en inventario por año. Se reconoce la necesidad de comparar estos enfoques clásicos con modelos avanzados. En etapas posteriores, el motor de IA podría integrar técnicas como LSTM o XGBoost, que han demostrado incrementos significativos en la precisión de la predicción de demanda [61]. Asimismo, modelos híbridos de forecasting y de aprendizaje por refuerzo profundo se consideran relevantes para escenarios de alta incertidumbre, lo que permitiría robustecer la solución frente a demandas intermitentes o altamente variables [25][63].

En una fase de implementación práctica, el entrenamiento de los modelos se desarrollaría siguiendo un proceso estructurado. En primer lugar, los registros históricos de ventas e inventarios pasarían por una etapa de preprocesamiento, donde se eliminarían valores atípicos y datos faltantes, además de aplicar técnicas de normalización [21]. Posteriormente, estos datos se dividirían en conjuntos de entrenamiento, validación y prueba con el fin de asegurar la calidad de los resultados [26]. A partir de ello, los

métodos clásicos como el suavizado exponencial simple y el modelo EOQ funcionarían como línea base, mientras que en paralelo se entrenarían modelos más avanzados, tales como LSTM, Random Forest y XGBoost, los cuales han demostrado incrementos considerables en la precisión de la predicción de demanda [18]. El modelo LSTM, por ejemplo, se alimentaría de series temporales de ventas por SKU para aprender patrones de estacionalidad y tendencias [53]; mientras que Random Forest y XGBoost integrarían variables adicionales como tiempos de entrega, promociones y factores externos para aumentar la precisión de las predicciones [19]. La validación de estos modelos se realizaría mediante métricas como MAE, RMSE y MAPE, aplicando técnicas de validación cruzada y optimización de hiperparámetros a fin de refinar el desempeño [60]. En cuanto al manejo de los datos, se plantea un pipeline automatizado que recoja información directamente desde sistemas POS o ERP hacia un repositorio central, ya sea una base de datos SQL o un data lake en la nube. Dicho pipeline ejecutaría tareas periódicas de limpieza, entrenamiento y actualización de modelos, cuyos resultados alimentarían al chatbot para entregar recomendaciones y alertas en tiempo real, garantizando así que las proyecciones reflejen el estado actual del negocio [50]; [34].

Finalmente, es importante destacar que la propuesta responde a una problemática concreta del entorno logístico, pero no pretende ser una solución única ni definitiva. Más bien, se presenta como una base sólida para el desarrollo futuro de herramientas inteligentes que puedan ser personalizadas de acuerdo con las características específicas de cada organización.

IV. RESULTADOS

Para la conceptualización y diseño del sistema propuesto basado en inteligencia artificial para la optimización logística, se adoptará un enfoque metodológico iterativo y flexible, inspirado en los principios de las metodologías ágiles como SCRUM. Este marco de trabajo permitirá gestionar la fase de diseño de manera eficiente y adaptable, facilitando la definición incremental de la arquitectura y las funcionalidades del prototipo, tal como se ilustra en la Tabla 1:

TABLA I
FASES DEL PROYECTO

1. Inicio	Elaboración del Acta de Constitución y análisis de interesados.
2. Planificación	Gestión del cronograma, costos, calidad y riesgos.
3. Ejecución	Diseño UI/UX, diseño del backend y frontend, integración de bases de datos.
4. Control	Aplicación de pruebas funcionales, de carga y control de calidad.
5. Cierre	Elaboración del informe final, firma de aceptación y cierre administrativo.

La Tabla 1 resume las fases principales del proyecto, desde la conceptualización inicial hasta la definición de la propuesta final. A partir de estas fases, se estructuraron las actividades en una Estructura Detallada del Trabajo (EDT)

para facilitar la planificación y organización del diseño del prototipo, como se muestra en la Figura 2:




Fig. 2 Descomposición de tareas EDT

En la figura 2 se muestran todas las actividades que se han planteado para la propuesta del proyecto, divididas en las fases de inicio, planificación, ejecución, control y cierre. De esta manera, se puede organizar mejor el trabajo del equipo y asegurar un seguimiento ordenado del avance del proyecto. Adicionalmente, se presentan un conjunto de métricas diseñadas para evaluar el desempeño técnico y funcional del sistema propuesto. Estas métricas permiten medir la eficiencia operativa, la experiencia del usuario y el impacto del sistema en la gestión de inventarios, tal como se detalla en la siguiente tabla:

TABLA II
KPIs DEL DESEMPEÑO DEL SISTEMA

Indicador	Medidor	Fórmula propuesta	Frecuencia	Resultado esperado (teórico)
Tasa de precisión de respuesta del chatbot	Porcentaje de respuestas correctas del chatbot	$(\text{Respuestas correctas} / \text{Total de respuestas}) * 100$	Por sesión simulada	[90%;100 %]
				[80%;90%)
				<80%
Nivel de satisfacción del usuario	Valoración promedio del usuario (escala 1-5)	Suma de valoraciones / Número de respuestas recibidas	Por sesión simulada	≥ 4.5
				[3.5;4.4]
				<3.5
Porcentaje de recomendaciones ejecutadas	% de sugerencias de IA que fueron	$(\text{Recomendaciones aplicadas} / \text{Total de recomendaciones})$	Por sesión simulada	≥ 70%
				[50%;70%)
				<50%

	aplicadas por usuarios	s generadas) * 100		
Reducción del stock desactualizado	% de mejora frente a inventario desactualizado	((Stock desactualizado anterior - actual) / Stock anterior) * 100	Mensual	≥ 30%
				[15%;30%]
Tasa de mejora en precisión de predicción	Comparación entre predicciones correctas antes y después del modelo	((Precisión final - Precisión inicial) / Precisión inicial) * 100	Bimestral	<15%
				≥ 20%
Reducción de quiebres de stock	Disminución porcentual de faltas de stock	((Quiebres anteriores - actuales) / Quiebres anteriores) * 100	Trimestral	[10%;20%]
				<10%
Interacciones resueltas sin asistencia humana	% de casos gestionados sin intervención humana	(Interacciones autónomas / Total de interacciones) * 100	Mensual	≥ 85%
				[70%;85%]
				<70%

La Tabla 3 presenta indicadores clave para evaluar el desempeño de un sistema con chatbot, incluyendo la precisión de respuestas, satisfacción del usuario, efectividad de recomendaciones, y su impacto en la gestión de inventarios. También mide la calidad de datos, la mejora en la predicción de demanda, la disponibilidad operativa y la autonomía del sistema. Estas métricas permiten analizar su rendimiento técnico bajo condiciones reales, facilitando el monitoreo y mejora continua. A continuación, se detallan los principales indicadores definidos.

TABLA III
KPIs TÉCNICOS DEL SISTEMA

Indicador	Medidor	Fórmula propuesta	Frecuencia	Resultado esperado (teórico)
Latencia promedio del sistema	Tiempo promedio desde solicitud hasta respuesta	Suma de latencias / Número total de solicitudes	Mensual	≤ 200 ms
				201–500 ms
Precisión del modelo de predicción de demanda	% de diferencia entre demanda predicha y real	100 - (Demanda real - Predicha / Demanda real) * 100	Mensual	≥ 90%
				80–89%
Velocidad de procesamiento de consultas	Cantidad de consultas procesadas por segundo	Total de consultas / Tiempo total de procesamiento (en segundos)	Por sesión simulada	≥ 50 q/s
				30–49 q/s
Consumo promedio de recursos (CPU/RAM)	% de utilización media de recursos del sistema	(Uso promedio CPU + Uso promedio RAM) / 2	Por sesión simulada	≤ 60%
				61–80%
Tasa de error del chatbot	% de respuestas incorrectas, incoherentes o fallidas	(Errores detectados / Total de respuestas del chatbot) * 100	Mensual	> 80%
				≤ 5%
Tiempo medio entre	Tiempo promedio de	Tiempo total de operación /	Bimestral	6–10%
				> 10%
				≥ 100 h
				50–99 h
				< 50 h

fallos (MTBF)	operación sin fallos	Número total de fallos		
Exactitud del procesamiento del lenguaje natural (PLN)	% de preguntas correctamente comprendidas	(Consultas correctamente interpretadas / Total de consultas) * 100	Mensual	≥ 95%
				85–94%
Integridad de datos	% de datos registrados sin pérdida ni error	(Registros válidos / Total de registros recibidos) * 100	Por sesión simulada	< 85%
				≥ 99%
				95–98%
				< 95%

La tabla 3 resume los criterios clave que permitirán evaluar el diseño y desempeño esperado del sistema propuesto. Dado que el presente trabajo se encuentra en una etapa conceptual, los umbrales de desempeño definidos para los indicadores han sido planteados de manera hipotética. No obstante, en una implementación práctica estos valores deberían derivarse de procesos de backtesting y de la comparación con líneas base obtenidas de sistemas tradicionales de gestión de inventarios. En la literatura, se evidencia que la validación empírica se sustenta en el uso de métricas como MAE, RMSE y MAPE, aplicadas de forma sistemática en pruebas de simulación [60]. Asimismo, el uso de técnicas de Monte Carlo para generar escenarios permite establecer intervalos de confianza realistas en indicadores como el stock de seguridad o el punto de reorden [30]. En entornos conversacionales, los KPIs asociados al rendimiento de chatbots, suelen evaluarse a través de experimentos controlados que simulan interacciones humanas bajo diferentes cargas de trabajo [67]. Bajo esta perspectiva, los KPIs definidos en este estudio deben entenderse como objetivos de referencia iniciales, que en fases posteriores de validación serán contrastados con datos reales para determinar su pertinencia y realizar los ajustes necesarios mediante iteraciones de prueba y optimización [23].

V. INTERACCIÓN DEL CHATBOT

Para ilustrar el funcionamiento del prototipo de sistema basado en inteligencia artificial orientado a la optimización logística, se presenta a continuación una descripción de la interacción y la estructura de los mensajes generados por el chatbot. Esta sección describe cómo el sistema procesa las consultas de los usuarios y entrega información predictiva y recomendaciones.

- Esquema de Interacción del Usuario con el Chatbot

El chatbot actúa como la interfaz principal para la interacción del usuario con el motor de IA. A través de comandos y preguntas en lenguaje natural, los usuarios pueden obtener información crucial para la toma de decisiones logísticas. A continuación, se presentan ejemplos de consultas típicas del usuario y las respuestas generadas por el sistema, demostrando la funcionalidad predictiva y de recomendación. Se visualizan los siguientes tipos de consultas:

- Alertas Predictivas

Cuando la IA identifica una situación de riesgo (ej. quiebre de stock, sobreabastecimiento), el chatbot emite una alerta, tal como se ve en la siguiente tabla:

TABLA IV
CONSULTA SOBRE ALERTAS PREDITIVAS
Consulta 2

Respuesta: ¡Perfecto, Usuario! Sobre lo que me pides de alertas predictivas de quiebre de stock o sobre abastecimiento, actualmente puedo ayudarte a identificar y analizar estos riesgos a partir de la proyección de demanda de tus SKU's, tiendas o ciudades. Para poder configurar esas alertas predictivas de forma efectiva, necesito saber un poco más: - ¿Quieres que analicemos todos los SKU's, alguna tienda o ciudad en particular? - ¿O prefieres que te haga un análisis global para detectar posibles quiebres y sobre abastecimientos en todo el negocio? Con esa información puedo hacer el primer análisis para detectar los puntos críticos y empezar a generar esas alertas. ¿Qué opción prefieres, Usuario?

Proceso Interno (IA): El sistema reconoce la intención del usuario de configurar alertas y, dado que la configuración requiere especificidad, el chatbot inicia un diálogo para recopilar los parámetros necesarios para el análisis predictivo.

• Proyecciones de Demanda

Para consultas sobre futuras necesidades, el chatbot proporciona estimaciones basadas en el análisis de datos históricos de ventas, tal como se ve en la tabla 5:

TABLA V
CONSULTA SOBRE PROYECCIONES DE DEMANDA
Consulta 3

Usuario: Ayúdame a realizar una proyección de demanda para el siguiente mes de mis 5 SKU más vendidos. Respuesta: He identificado los 5 SKU's más vendidos y preparé una proyección de demanda para el próximo mes basada en el análisis global del negocio. El SKU principal muestra estabilidad con tendencia moderada y sin alertas críticas de stock. La demanda proyectada para enero 2025 es alentadora, con un ligero crecimiento esperado. Top 5 SKUs más vendidos (extracto) 0201220000003 — 5,493 unidades actuales, tendencia estable 122023 — 3,591 unidades, tendencia decreciente 7750151007092 — 2,751 unidades, tendencia estable 0296304000000 — 2,339 unidades, tendencia creciente 7750243079990 — 2,215 unidades, tendencia creciente Proyección de demanda para enero 2025 (solo SKU principal destacado) - SKU: 0201220000003 - Proyección: 3,052 unidades - Rango esperado: 3,759 a 5,492 unidades - Prioridad inventario: Alta La demanda muestra una estimación con un rango amplio que indica posibles variaciones, por lo que es importante monitorear el inventario para evitar quiebres o sobreabastecimientos. Alertas Actualmente no hay alertas críticas detectadas en esta proyección para los SKU's principales.

Proceso Interno (IA): El Módulo de Análisis Predictivo utiliza modelos de series de tiempo y datos históricos de ventas de una categoría específica para generar una estimación de la demanda futura. Para una comprensión visual de la interacción, se puede presentar un diagrama de flujo simple

que muestre cómo la consulta del usuario se traduce en una respuesta del chatbot, tal como se muestra en la siguiente figura:




Fig. 3 Diagrama de Flujo del Chatbot

El flujo inicia cuando el usuario envía una consulta al chatbot, que interpreta la intención y la remite al motor de IA. Este accede a bases de datos (ventas, inventario, pedidos) y, mediante análisis predictivo, genera recomendaciones o alertas. Luego, el chatbot entrega la respuesta de forma clara. Todo el proceso se apoya en la integración con sistemas como ERP o POS para asegurar datos precisos y actualizados.

VI. DISCUSIÓN

La literatura confirma que la inteligencia artificial (IA) ha transformado significativamente la gestión de inventarios en entornos altamente digitalizados, generando ventajas competitivas medibles en contextos de alta incertidumbre, variabilidad de la demanda y limitación de datos. Modelos como Random Forest, XGBoost y LSTM han incrementado la precisión en la previsión de demanda hasta en un 20 %, y reducido los costos operativos hasta en un 15 % gracias a un reabastecimiento más eficiente [60][61]. En entornos dinámicos, enfoques como el aprendizaje por refuerzo multiagente y los Deep Q-Networks han demostrado eficacia al optimizar decisiones y reducir quiebres de stock [25][62]. Asimismo, los modelos de forecasting probabilístico han superado a los métodos tradicionales en la gestión de demandas intermitentes [63], mientras que los sistemas semiautomatizados con IA han mejorado el monitoreo en tiempo real, reduciendo la incidencia de quiebres de stock [64]. Un aspecto clave asociado al despliegue en entornos reales es que el uso de datos provenientes de sistemas ERP y POS implica la necesidad de garantizar la privacidad y la seguridad de la información, adoptando medidas de encriptación y control de accesos para prevenir vulnerabilidades [52]. La integración de un chatbot basado en modelos de lenguaje debe considerar riesgos como la generación de respuestas no verificadas y la necesidad de

establecer guardrails que limiten su comportamiento a un marco de seguridad y transparencia [34]. Asimismo, la literatura advierte que los modelos de IA aplicados a la gestión de inventarios pueden reflejar sesgos presentes en los datos de entrenamiento y afectar la equidad en la toma de decisiones, por lo que se recomienda incorporar mecanismos de explicabilidad y auditoría periódica [48]. De esta manera, el despliegue del sistema no solo debe enfocarse en la eficiencia técnica, sino también en asegurar una gobernanza responsable que minimice riesgos éticos y operativos.

La incorporación de agentes conversacionales, sistemas híbridos y estructuras basadas en aprendizaje reforzado ha superado la rigidez de estrategias clásicas como la política (s, Q) [17][26]. Estas innovaciones se alinean con marcos recientes que promueven soluciones modulares, escalables y de bajo requerimiento técnico, orientadas a mejorar la trazabilidad, eficiencia y autonomía en la toma de decisiones [3][21]. A partir de esta evidencia, el presente estudio propone un diseño proyectivo adaptado al contexto de las pymes comerciales del norte del Perú. La solución combina modelos predictivos ligeros, un motor de IA con lógica de reabastecimiento, y una interfaz conversacional vía chatbot, lo que permite su adopción por usuarios no técnicos. Más que replicar sistemas industriales complejos, esta herramienta busca apoyar decisiones logísticas, reducir la dependencia del criterio empírico y contribuir de forma gradual a la transformación digital del sector.

VII. CONCLUSIONES

- El diseño del prototipo de sistema basado en inteligencia artificial demostró ser una solución viable y contextualizada para enfrentar las deficiencias logísticas que afectan al sector comercial en Trujillo. Mediante una arquitectura modular, un motor predictivo y una interfaz conversacional intuitiva, se logró conceptualizar una herramienta que integra modelos de predicción de demanda, alertas automatizadas y recomendaciones, lo cual contribuye significativamente a mejorar la eficiencia operativa, reducir errores humanos y apoyar la toma de decisiones basada en datos.
- Se logró definir una arquitectura conceptual robusta, conformada por módulos interconectados que permiten una gestión eficiente del flujo de información. Esta arquitectura contempla entrada de datos, procesamiento mediante IA y una capa de interacción con el usuario, permitiendo un diseño escalable y adaptable a distintos escenarios logísticos.
- Se identificaron como fuentes clave de datos los registros históricos de ventas, inventarios y tiempos de entrega, los cuales son esenciales para alimentar los modelos predictivos del sistema. Además, se establecieron los requisitos funcionales y técnicos necesarios para garantizar un correcto desempeño, considerando tanto necesidades del usuario como limitaciones propias de las pymes de la región.
- Se propusieron modelos de inteligencia artificial basados en técnicas como el suavizado exponencial y cálculos de stock de seguridad, integrados a una lógica conversacional mediante un chatbot. Este enfoque facilita la interacción con usuarios no técnicos y permite una gestión predictiva dinámica, adaptada a la realidad comercial local.
- Se definió un conjunto integral de métricas de evaluación tanto funcionales como técnicas, orientadas a medir precisión, eficiencia, satisfacción del usuario y reducción de errores logísticos. Estas métricas permitirán validar el desempeño del sistema en futuras implementaciones y facilitarán su mejora continua.

REFERENCIAS

- [1] Wang, H., Sua, L. S., y Alidaee, B. (2024). Enhancing supply chain security with automated machine learning (No. arXiv:2406.13166). arXiv. <https://doi.org/10.48550/arXiv.2406.13166>
- [2] Ahn, H., Olivar, S., Mehta, H., y Song, Y. C. (2024). Generative Probabilistic Planning for Optimizing Supply Chain Networks (No. arXiv:2404.07511). arXiv. <https://doi.org/10.48550/arXiv.2404.07511>
- [3] Goriparthi, R. G. (2021). Optimizing Supply Chain Logistics Using AI and Machine Learning Algorithms. International Journal of Advanced Engineering Technologies and Innovations, 1(2), Article 2. [10.71143/n5d6ff98](https://doi.org/10.71143/n5d6ff98)
- [4] Chen, W., Men, Y., Fuster, N., Osorio, C., y Juan, A. A. (2024). Artificial Intelligence in Logistics Optimization with Sustainable Criteria: A Review. Sustainability, 16(21), Article 21. <https://doi.org/10.3390/su16219145>
- [5] Nagavalli, S. P., y Dey, S. (2021). AI-Powered Supply Chain Optimization: Enhancing eCommerce Logistics through Machine Learning. International Journal of Emerging Trends in Computer Science and Information Technology, 2(2), Article 2. <https://doi.org/10.63282/3050-9246.IJETSIT-V2I2P103>
- [6] Tatipamula, S. (2025). AI in Logistics: Smarter Inventory and Shipment Optimization. International Journal of Scientific Research in Computer Science, Engineering and Information Technology, 11(2), Article 2. <https://doi.org/10.32628/CSEIT25112813>
- [7] Iklassov, Z., Sobirov, I., Solozabal, R., y Takac, M. (2024). Reinforcement Learning for Solving Stochastic Vehicle Routing Problem with Time Windows (No. arXiv:2402.09765). arXiv. <https://doi.org/10.48550/arXiv.2402.09765>
- [8] Lin, B., Ghaddar, B., y Nathwani, J. (2022). Deep Reinforcement Learning for Electric Vehicle Routing Problem with Time Windows. IEEE Transactions on Intelligent Transportation Systems, 23(8), 11528-11538. <https://doi.org/10.1109/TITS.2021.3105232>
- [9] Zhang, K., He, F., Zhang, Z., Lin, X., y Li, M. (2020). Multi-vehicle routing problems with soft time windows: A multi-agent reinforcement learning approach. Transportation Research Part C: Emerging Technologies, 121, 102861. <https://doi.org/10.1016/j.trc.2020.102861>
- [10] Li, X., Zhang, J., Bian, J., Tong, Y., y Liu, T.-Y. (2019). A Cooperative Multi-Agent Reinforcement Learning Framework for Resource Balancing in Complex Logistics Network (No. arXiv:1903.00714). arXiv. <https://doi.org/10.48550/arXiv.1903.00714>
- [11] Nozari, H., Rahmaty, M., Foukolaei, P. Z., Movahed, H., y Bayanati, M. (2025). Optimizing Cold Chain Logistics with Artificial Intelligence of Things (AIoT): A Model for Reducing Operational and Transportation Costs. Future Transportation, 5(1), Article 1. <https://doi.org/10.3390/futuretransp5010001>
- [12] Bruni, M. E., Fadda, E., Fedorov, S., y Perboli, G. (2023). A machine learning optimization approach for last-mile delivery and

- third-party logistics. *Computers y Operations Research*, 157, 106262. <https://doi.org/10.1016/j.cor.2023.106262>
- [13] Liu, Q. (2024). Logistics Distribution Route Optimization in Artificial Intelligence and Internet of Things Environment. *Decision Making: Applications in Management and Engineering*, 7, 221-239. <https://doi.org/10.31181/dmame.7220241072>
 - [14] Jahin, M. A., Shovon, M. S. H., Islam, M. S., Shin, J., Mridha, M. F., y Okuyama, Y. (2023). QAmplifyNet: Pushing the Boundaries of Supply Chain Backorder Prediction Using Interpretable Hybrid Quantum-Classical Neural Network (No. arXiv:2307.12906). arXiv. <https://doi.org/10.48550/arXiv.2307.12906>
 - [15] Tan, K., Liu, W., Xu, F., y Li, C. (2023). Optimization Model and Algorithm of Logistics Vehicle Routing Problem under Major Emergency. *Mathematics*, 11(5), Article 5. <https://doi.org/10.3390/math11051274>
 - [16] Sharma, V. (2020). Leveraging Machine Learning to Enhance the Efficiency of Retail Supply Chains. 11, 9. <https://doi.org/10.5281/zenodo.14715773>
 - [17] Gurumurthy, R., Pereira, R., y Pereira, A. (2024, septiembre 24). AI in Inventory Management. 3rd Australian Conference on Industrial Engineering and Operations Management. <https://doi.org/10.46254/AU03.20240064>
 - [18] Tan, Y., Gu, L., Xu, S., y Li, M. (2024). Supply Chain Inventory Management from the Perspective of “Cloud Supply Chain”—A Data Driven Approach. *Mathematics*, 12(4), Article 4. <https://doi.org/10.3390/math12040573>
 - [19] Pasupuleti, V., Thuraka, B., Kodete, C. S., y Malisetty, S. (2024). Enhancing Supply Chain Agility and Sustainability through Machine Learning: Optimization Techniques for Logistics and Inventory Management. *Logistics*, 8(3), Article 3. <https://doi.org/10.3390/logistics8030073>
 - [20] Li, Q. (2021). Inventory Method of Intelligent Logistics Warehouse Based on Artificial Intelligence. *Journal of Physics: Conference Series*, 2037(1), 012102. <https://doi.org/10.1088/1742-6596/2037/1/012102>
 - [21] Çaylı, O., y Oralhan, Z. (2024). Artificial Intelligence-Driven Inventory Management: Optimizing Stock Levels and Reducing Costs Through Advanced Machine Learning Techniques. *The European Journal of Research and Development*, 4(4), Article 4. <https://doi.org/10.56038/ejrd.v4i4.615>
 - [22] Yeldan, G., Yılmaz, G., y Kayatürk, G. (2024). AI-Driven Optimization of Order Procurement and Inventory Management in Supply Chains. *The European Journal of Research and Development*, 4(3), Article 3. <https://doi.org/10.56038/ejrd.v4i3.605>
 - [23] D’Souza, S. (2021). Implementing Reinforcement Learning Algorithms in Retail Supply Chains with OpenAI Gym Toolkit (No. arXiv:2104.14398). arXiv. <https://doi.org/10.48550/arXiv.2104.14398>
 - [24] Kosasih, E. E., y Brintrup, A. (2021). Reinforcement Learning Provides a Flexible Approach for Realistic Supply Chain Safety Stock Optimisation (No. arXiv:2107.00913). arXiv. <https://doi.org/10.48550/arXiv.2107.00913>
 - [25] Kalusivalingam, A. K., Sharma, A., Patel, N., y Singh, V. (2020). Optimizing Inventory Management with AI: Leveraging Deep Reinforcement Learning and Neural Networks for Enhanced Demand Forecasting and Stock Replenishment. *International Journal of AI and ML*, 1(3), Article 3. <https://cognitivecomputingjournal.com/index.php/IJAIML-V1/article/view/43>
 - [26] Leluc, R., Kadoche, E., Bertoncello, A., y Gourvénec, S. (2023). MARLIM: Multi-Agent Reinforcement Learning for Inventory Management (No. arXiv:2308.01649). arXiv. <https://doi.org/10.48550/arXiv.2308.01649>
 - [27] Stranieri, F., y Stella, F. (2025). Comparing Deep Reinforcement Learning Algorithms in Two-Echelon Supply Chains (pp. 454-469). https://doi.org/10.1007/978-3-031-74640-6_37
 - [28] Perez, H. D., Hubbs, C. D., Li, C., y Grossmann, I. E. (2021). Algorithmic Approaches to Inventory Management Optimization. *Processes*, 9(1), Article 1. <https://doi.org/10.3390/pr9010102>
 - [29] Hammler, P., Riesterer, N., y Braun, T. (2023). Fully dynamic reorder policies with deep reinforcement learning for multi-echelon inventory management. *Informatik Spektrum*, 46(5), 240-251. <https://doi.org/10.1007/s00287-023-01556-6>
 - [30] Preil, D., y Krapp, M. (2022). Artificial intelligence-based inventory management: A Monte Carlo tree search approach. *Annals of Operations Research*, 308(1), 415-439. <https://doi.org/10.1007/s10479-021-03935-2>
 - [31] Tong, C. (2025). An Efficient Intelligent Semi-Automated Warehouse Inventory Stocktaking System (No. arXiv:2309.12365). arXiv. <https://doi.org/10.48550/arXiv.2309.12365>
 - [32] Fernández-Caramés, T. M., Blanco-Novoa, O., Froiz-Míguez, I., y Fraga-Lamas, P. (2019). Towards an Autonomous Industry 4.0 Warehouse: A UAV and Blockchain-Based System for Inventory and Traceability Applications in Big Data-Driven Supply Chain Management. *Sensors*, 19(10), Article 10. <https://doi.org/10.3390/s19102394>
 - [33] Temizöz, T., Imdahl, C., Dijkman, R., Lamghari-Idrissi, D., y Jaarsveld, W. van. (2025). Deep Controlled Learning for Inventory Control. *European Journal of Operational Research*, 324(1), 104-117. <https://doi.org/10.1016/j.ejor.2025.01.026>
 - [34] Quan, Y., y Liu, Z. (2025). InvAgent: A Large Language Model based Multi-Agent System for Inventory Management in Supply Chains (No. arXiv:2407.11384). arXiv. <https://doi.org/10.48550/arXiv.2407.11384>
 - [35] Kegenbekov, Z., y Jackson, I. (2021). Adaptive Supply Chain: Demand-Supply Synchronization Using Deep Reinforcement Learning. *Algorithms*, 14(8), Article 8. <https://doi.org/10.3390/a14080240>
 - [36] Wan, T., y Hong, L. J. (2022). Large-Scale Inventory Optimization: A Recurrent-Neural-Networks-Inspired Simulation Approach (No. arXiv:2201.05868). arXiv. <https://doi.org/10.48550/arXiv.2201.05868>
 - [37] Böttcher, L., Asikis, T., y Fragkos, I. (2023). Control of Dual-Sourcing Inventory Systems using Recurrent Neural Networks. *INFORMS Journal on Computing*, 35(6), 1308-1328. <https://doi.org/10.1287/ijoc.2022.0136>
 - [38] Sultana, N. N., Meisheri, H., Baniwal, V., Nath, S., Ravindran, B., y Khadilkar, H. (2020). Reinforcement Learning for Multi-Product Multi-Node Inventory Management in Supply Chains (No. arXiv:2006.04037). arXiv. <https://doi.org/10.48550/arXiv.2006.04037>
 - [39] Dittich, M.-A., y Fohlmeister, S. (2021). A deep q-learning-based optimization of the inventory control in a linear process chain. *Production Engineering*, 15(1), 35-43. <https://doi.org/10.1007/s11740-020-01000-8>
 - [40] Piao, M., Zhang, D., Lu, H., y Li, R. (2023). A Supply Chain Inventory Management Method for Civil Aircraft Manufacturing Based on Multi-Agent Reinforcement Learning. *Applied Sciences*, 13(13), Article 13. <https://doi.org/10.3390/app13137510>
 - [41] Zhang, Y., He, L., y Zheng, J. (2025). A Deep Reinforcement Learning-Based Dynamic Replenishment Approach for Multi-Echelon Inventory Considering Cost Optimization. *Electronics*, 14(1), Article 1. <https://doi.org/10.3390/electronics14010066>
 - [42] Mandala, V. (2024). Revolutionizing Automotive Supply Chain: Enhancing Inventory Management with AI and Machine Learning. *Universal Journal of Computer Sciences and Communications*, 10-22. <https://doi.org/10.31586/ujcsc.2024.918>
 - [43] Suman Choudhuri, S. (2024). AI - Driven Supply Chain Optimization: Enhancing Inventory Management, Demand

- Forecasting, and Logistics within ERP Systems. *International Journal of Science and Research (IJSR)*, 13(3), 927-933. [10.21275/SR24314073027](https://doi.org/10.21275/SR24314073027)
- [44] Porfirio, T. C., Saul, M. A., y Rodríguez, Á. G. (2024). LA INTELIGENCIA ARTIFICIAL Y SU IMPACTO EN LA GESTIÓN DE INVENTARIOS EN LA CADENA DE SUMINISTRO. *LUMEN ET VIRTUS*, 15(43), Article 43. <https://doi.org/10.56238/levv15n43-037>
- [45] Villegas-Ch, W., Navarro, A. M., y Sanchez-Viteri, S. (2024). Optimization of inventory management through computer vision and machine learning technologies. *Intelligent Systems with Applications*, 24, 200438. <https://doi.org/10.1016/j.iswa.2024.200438>
- [46] Ibarra-Peña, K. A., Morán-Murillo, P. N., y Rodríguez-Sares, E. A. (2024). Inteligencia artificial y Big Data en la optimización de cadenas de suministro internacionales: Hacia una logística predictiva y sostenible. *Revista UGC*, 2(3), Article 3. <https://universidaduc.edu.mx/ojs/index.php/rugc/article/view/55>
- [47] Somerstein, R. (s. f.). 3 hospital supply chain directors explain how AI is helping them manage critical inventory. *Business Insider*. Recuperado 4 de julio de 2025, de <https://www.businessinsider.com/ai-hospital-inventory-management-advice-mayo-clinic-cleveland-clinic-2025-5>
- [48] Richey Jr., R. G., Chowdhury, S., Davis-Sramek, B., Giannakis, M., y Dwivedi, Y. K. (2023). Artificial intelligence in logistics and supply chain management: A primer and roadmap for research. *Journal of Business Logistics*, 44(4), 532-549. <https://doi.org/10.1111/jbl.12364>
- [49] Cachay, D. L. C. (2023). La inteligencia artificial y su incidencia en el mercado laboral peruano. *Revista de Derecho Procesal del Trabajo*, 6(8), Article 8. <https://doi.org/10.47308/rdpt.v6i8.752>
- [50] Romero, J. P. (2024). Desempeño de la IA en la búsqueda de fuentes especializadas y escritura de textos académicos. *Lengua y Sociedad*, 23(2), Article 2. <https://doi.org/10.15381/lengsoc.v23i2.27856>
- [51] Chumplitaz, D. S. S., Rodríguez, V. V. L., y Caro, G. L. A. (2024). Impacto de la inteligencia artificial en la competitividad logística: El megapuerto de Chancay en Perú como conector entre la República Popular China y América Latina. *Revista de Análisis y Difusión de Perspectivas Educativas y Empresariales*, 4(9), Article 9. <https://doi.org/10.56216/radee032024dic.a01>
- [52] Cortez-Vásquez, A., y Conde, R. U. G. (2024). La Inteligencia artificial y sus implicancias en el Control Interno y la Gestión de los Inventarios. *Revista de investigación de Sistemas e Informática*, 17(2), Article 2. <https://doi.org/10.15381/risi.v17i2.29918>
- [53] Ticona-Salluca, H., Torres-Cruz, F., y Tumi-Figueroa, E. N. (2023). Machine Learning Applied to Peruvian Vegetables Imports (No. arXiv:2301.03587). <https://doi.org/10.48550/arXiv.2301.03587>
- [54] Espinosa-Luna, B. H., Castillo-Oliva, J., Montañez-Díaz, B. A., y Mendoza-De-los-Santos, A. (2023). Implementación de un chatbot basado en modelo de lenguaje de inteligencia artificial para responder preguntas frecuentes de estudiantes universitarios. *Revista Científica de Sistemas e Informática*, 3(2), Article 2. <https://doi.org/10.51252/rcsi.v3i2.570>
- [55] Alván, P., Arteaga, E., Cruzado, E., Morales, J., Rojas, W., Sánchez, L., Zegarra, J., y Prado, R. (2018). Diseño e implementación de una dispensadora de bebidas automática "Barbot". *REVISTA TECNOLOGÍA y DESARROLLO*, 16(1), 58-67. <https://doi.org/10.18050/td.v16i1.1954>
- [56] Warwick, K. (2012). *Artificial intelligence: The basics*. Routledge.
- [57] Alpaydin, E. (2020). *Introduction to machine learning* (Fourth edition). The MIT Press.
- [58] Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT Press.
- [59] Russell, S. J., y Norvig, P. (with Chang, M., Devlin, J., Dragan, A., Forsyth, D., Goodfellow, I., Malik, J., Mansinghka, V., Pearl, J., y Wooldridge, M. J.). (2022). *Artificial intelligence: A modern approach* (Fourth edition, global edition). Pearson.
- [60] O. R. Amosu, P. Kumar, Y. M. Ogunsuji, S. Oni y O. Faworaja, "AI-driven demand forecasting: Enhancing inventory management and customer satisfaction," *World Journal of Advanced Research and Reviews*, vol. 23, no. 2, pp. 708–719, 2024. Disponible en: <https://doi.org/10.30574/wjarr.2024.23.2.2394>
- [61] K K, R., K K, K., Kalyan, N. B., Tiwari, M., Raju, G., & Ganesh, K. (2024). Improving Retail Industry Inventory Management Using Machine Learning (pp. 137-141). <https://doi.org/10.1201/9781003531395-28>
- [62] Shawon, R. E. R., Hasan, M. R., Rahman, M. A., Ghandri, M., Lamari, I. A., Kawsar, M., and Akter, R. (2025). Designing and Deploying AI Models for Sustainable Logistics Optimization: A Case Study on Eco-Efficient Supply Chains in the USA. *Journal of Ecohumanism*, 4(2). <https://doi.org/10.62754/joe.v4i2.6610>
- [63] S. Wang, Y. Kang, y F. Petropoulos, "Combining Probabilistic Forecasts of Intermittent Demand," *arXiv*, 2023. Disponible en: <https://arxiv.org/abs/2304.03092>
- [64] C. Tong, "An Efficient Intelligent Semi-Automated Warehouse Inventory Stocktaking System," *arXiv*, 2023. Disponible en: <https://arxiv.org/abs/2309.12365>
- [65] Waller, M. A., & Fawcett, S. E. (2013). Click Here for a Data Scientist: Big Data, Predictive Analytics, and Theory Development in the Era of a Maker Movement Supply Chain. *Journal of Business Logistics*, 34(4), 249-252. <https://doi.org/10.1111/jbl.12024>
- [66] Davenport, T. H., & Dyché, J. (2013). *Big Data in Big Companies*.
- [67] McTear et al., 2016: McTear, M., Callejas, Z., y Griol, D. (2016). *The Conversational Interface: Talking to Smart Devices*. Springer. [10.1007/978-3-319-32967-3](https://doi.org/10.1007/978-3-319-32967-3)
- [68] Chopra, S., y Meindl, P. (2019). *Supply Chain Management: Strategy, Planning, and Operation* (7th ed.). Pearson.
- [69] Simchi-Levi, D., Kaminsky, P., y Simchi-Levi, E. (2014). *Designing and Managing the Supply Chain: Concepts, Strategies, and Case Studies* (4th ed.). McGraw-Hill Education.
- [70] Coyle, J. J., Langley, C. J., Gibson, B. J., Novack, R. A., y Bardi, E. J. (2017). *Supply Chain Management: A Logistics Perspective* (10th ed.). Cengage Learning.
- [71] Slack, N., Brandon-Jones, A., y Johnston, R. (2016). *Operations Management* (8th ed.). Pearson.