



Universidad Católica de Santa María

Facultad de Ciencias e Ingenierías Físicas y Formales

Escuela Profesional de Ingeniería de Sistemas

**Aplicación de modelos de lenguaje de gran escala para apoyar la toma de
decisiones en la gestión de inventarios en MYPES comerciales de Arequipa,
2025**

Tesis presentada por:

Gomez Quispe, Gerald Edwin

ORCID: 0009-0002-8378-2636

para optar el Título Profesional de Ingeniero de Sistemas

Asesor (a):

Dr. Paredes Marchena, Fernando German

ORCID: 0000-0003-2081-4100

Arequipa - Perú

2026

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE SISTEMAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 27 de Mayo del 2026

Dictamen: 017676-C-EPIS-2026

Visto el borrador del expediente 017676, presentado por:

2021243051 - GOMEZ QUISPE GERALD EDWIN

Titulado:

**APLICACIÓN DE MODELOS DE LENGUAJE DE GRAN ESCALA PARA APOYAR LA TOMA DE
DECISIONES EN LA GESTIÓN DE INVENTARIOS EN MYPES COMERCIALES DE AREQUIPA, 2025**

Nuestro dictamen es:

APROBADO

Título Profesional/Título de Segunda Especialidad/Grado Académico a optar:

INGENIERO DE SISTEMAS

**29601217 - ROSAS PAREDES KARINA
DICTAMINADOR**



**40375371 - LAZO BARREDA DELY MARYSHECK
DICTAMINADOR**



**40942819 - SANTILLANA VALDIVIA MARIO CESAR
DICTAMINADOR**



APLICACIÓN DE MODELOS DE LENGUAJE DE GRAN ESCALA PARA APOYAR LA TOMA DE DECISIONES EN LA GESTIÓN DE INVENTARIOS EN MYPES COMERCIALES DE AREQUIPA, 2025

INFORME DE ORIGINALIDAD

19%	17%	9%	9%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Carlos III de Madrid - EUR	1%
	Trabajo del estudiante	
2	dspace.ups.edu.ec	<1%
	Fuente de Internet	
3	tesis.ucsm.edu.pe	<1%
	Fuente de Internet	
4	bibdigital.epn.edu.ec	<1%
	Fuente de Internet	
5	Submitted to Universitat Oberta de Catalunya	<1%
	Trabajo del estudiante	
6	Submitted to Universidad Andrés Bello	<1%
	Trabajo del estudiante	
7	Submitted to Universidad Europea de Madrid	<1%
	Trabajo del estudiante	
8	www.urbanspoon.com	<1%
	Fuente de Internet	
9	uvadoc.uva.es	<1%
	Fuente de Internet	
10	dialnet.unirioja.es	<1%
	Fuente de Internet	

DEDICATORIA

A mis padres, por su amor incondicional, su apoyo constante y por ser mi mayor inspiración en cada paso de este camino; a mis profesores y mentores, cuyo conocimiento y guía han sido fundamentales en mi formación; y a mis amigos, por su compañía y aliento en los momentos más desafiantes.



AGRADECIMIENTOS

En primer lugar, quiero agradecer a Dios y a mi familia por haber sido el apoyo y la motivación permanente durante mi formación académica y personal. A mis padres por el esfuerzo, amor y confianza incondicional que les permitió llegar a esta etapa tan importante de mi vida profesional.

Quiero agradecer a mis profesores y asesores de la Escuela Profesional de Ingeniería de Sistemas de la Universidad Católica de Santa María y especialmente a mis asesores de la presente tesis por los conocimientos, orientación y apoyo brindado en cada etapa de la investigación.

También quiero agradecer a mis compañeros y amigos con quienes compartí experiencias, aprendizajes y momentos que enriquecieron mi vida universitaria y que ayudaron a mi desarrollo personal y profesional.

Finalmente, mi agradecimiento a las micro y pequeñas empresas de Arequipa que aportaron con su información y voluntad para la validación del presente estudio, pues fue posible aplicar en la práctica la presente propuesta gracias a su participación.

RESUMEN

Para las MYPES comerciales de Arequipa, la gestión de inventarios es uno de los mayores retos, ya que no cuentan con herramientas tecnológicas que les permitan acceder de manera oportuna a la información y optimizar la toma de decisiones. Hoy en día muchas de estas empresas dependen de métodos manuales y empíricos que generan problemas de desabastecimiento, *sobrestock* y baja competitividad.

La presente investigación propone el desarrollo de un sistema de apoyo a la toma de decisiones basado en Modelos de Lenguaje de Gran Escala (LLM), orientado a facilitar la consulta y análisis de información sobre la gestión de inventarios. El sistema será diseñado como un prototipo funcional con interfaz conversacional en lenguaje natural que permita a los responsables de las MYPES acceder de forma más ágil y comprensible a datos históricos y actuales para apoyar la toma de decisiones.

Metodológicamente, el estudio es de tipo aplicado, con un diseño pre-experimental de un solo grupo con *Pre-Test* y *Post-Test*, utilizando técnicas cuantitativas mediante cuestionarios estructurados y observación complementaria en MYPES seleccionadas.

Se medirá el impacto del sistema en la toma de decisiones mediante la aplicación de un cuestionario tipo Likert en dos momentos (antes y después de la presentación del prototipo). Se espera que la propuesta contribuya a mejorar el acceso a la información de inventarios, fortalecer la toma de decisiones basada en datos y facilitar la interpretación de información relevante para los responsables de las MYPES comerciales de Arequipa.

Palabras claves: Modelos de Lenguaje de Gran Escala, Gestión de Inventarios, Toma de decisiones.

ABSTRACT

One of the major challenges for micro and small commercial enterprises (MSEs) in Arequipa is the management of inventories, due to the lack of technological tools that provide timely access to information and facilitate optimal decision-making. Many of these firms today are using manual and empirical practices that lead to problems like stock-outs, overstock and low competitiveness.

The objective of this study is to create a decision-support system, based on Large Language Models (LLMs), to support the consultation and analysis of information on inventory management. It is intended to develop the system as a functional prototype with a conversational interface in natural language, which will enable MSE managers to access historical and current data in a more agile and understandable way to support decision-making.

Methodologically, this research is of an applied nature using a pre-experimental design of one group with a Pre-Test and Post-Test. It uses quantitative methods via structured questionnaires and additional observation in selected MYPEs. In order to evaluate the impact on decision making systems, a Likert-scale questionnaire will be applied at two moments, before and after the prototype presentation.

The proposal is anticipated to contribute to improving access to inventory information, strengthening data-driven decision-making, and facilitating the interpretation of relevant information for those responsible for commercial MYPEs in Arequipa.

Keywords: Large Language Models, Inventory Management, Decision-making.

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCIÓN.....1

CAPÍTULO I.....3

1. PLANTEAMIENTO DE LA INVESTIGACION.....4

1.1. Planteamiento del Problema:4

1.2. Objetivos de la Investigación5

1.2.1. Objetivo General.....5

1.2.2. Objetivos Específicos5

1.3. Preguntas de Investigación:.....6

1.4. Formulación de la Hipótesis, Variables, Indicadores:.....6

1.5. Línea y Sub-línea de Investigación a la que corresponde el Problema.....8

1.6. Palabras Clave9

1.7. Solución Propuesta.9

1.7.1. Justificación e Importancia.....9

1.7.2. Descripción de la Solución9

1.7.3. Aporte10

1.7.4. Matriz de Operacionalización de Variables10

1.7.5. Matriz de Consistencia13

CAPÍTULO II.....	15
2. FUNDAMENTOS TEÓRICOS.....	16
2.1. Antecedentes de la Investigación.....	16
2.2. Estado del arte	20
2.3. Bases Teóricas de la Investigación.....	37
2.3.1. Inteligencia Artificial en la Gestión de Inventarios	37
2.3.2. Modelos de Lenguaje de Gran Escala (LLM).....	38
2.3.3. Visualización de Datos y Herramientas de Business Intelligence.....	39
2.3.4. Gestión de Inventarios en Micro y Pequeñas Empresas	40
CAPÍTULO III	42
3. MARCO METODOLOGICO.....	43
3.1. Alcances y Limitaciones	43
3.2. Tipo y Nivel de la Investigación	44
3.3. Universo, Población y Muestra	45
3.4. Métodos, Técnicas e Instrumentos de Recolección de Datos	47
3.5. Plan de Análisis Estadístico de los Datos.....	50
3.6. Consideraciones Éticas sobre el Uso de IA Generativa.....	53
3.7. CRONOGRAMA.....	54
CAPÍTULO IV	57
4. Desarrollo de la Solución Tecnológica	58
4.1. Contexto del Desarrollo y Metodología SCRUM	58
4.1.1.Contexto del Desarrollo	58

4.1.2. Metodología SCRUM	58
4.1.3. Descripción del entorno (MYPES comerciales de Arequipa).....	59
4.1.4. Justificación del uso de SCRUM en el desarrollo del Chatbot.....	60
4.1.5. Roles definidos: Product Owner, Scrum Master, Development.....	60
4.1.6. Fases del proceso ágil:.....	61
4.1.7. Cronograma general de los sprints	62
4.2. Requerimientos del Sistema.....	63
4.2.1. Requerimientos Funcionales.....	63
4.2.2. Requerimientos No Funcionales.....	66
4.3. Arquitectura del Sistema Propuesto	70
4.3.1. Diagrama de arquitectura	70
4.3.2. Explicación de los módulos	71
4.3.3. Interacción general del sistema	72
4.4. Diseño del Sistema	73
4.4.1. Diagramas de flujo del proceso de consulta.....	73
4.4.2. Casos de uso principales	74
4.4.3. Boceto de la interfaz del Chatbot.....	90
4.5. Desarrollo e Implementación bajo SCRUM	93
4.5.1. Sprint 1 – Configuración del entorno y conexión de datos.....	93
4.5.2. Sprint 2 – Desarrollo del Chatbot LLM.....	97
4.5.3. Sprint 3 – Implementación del módulo y pruebas.....	101
4.6. Validación Técnica y Funcional de la Solución	108

4.6.1. Pruebas unitarias.....	108
4.6.2. Pruebas integradas	109
4.6.3. Encuesta Post-Test a usuarios	110
4.7. Análisis costo-beneficio de la implementación.....	111
CAPÍTULO V	113
5. RESULTADOS	114
5.1. Presentación de los datos recopilados.....	114
5.2. Resultados del uso del sistema.....	116
5.3. Evaluación del impacto en la toma de decisiones	118
5.4. Validación de hipótesis	119
5.5. Discusión.....	123
5.5.1. Comparación con trabajos previos	123
5.5.2. Fortalezas y limitaciones de la propuesta.....	124
CONCLUSIONES.....	126
RECOMENDACIONES.....	128
TRABAJOS FUTUROS	130
REFERENCIAS	132
ANEXOS	142
ANEXO A. Encuesta Pre-Test	142
ANEXO B. Encuesta Post-Test.....	144
ANEXO C. Conjunto de Datos.....	146

ÍNDICE DE TABLAS

Tabla 1 Variables de Investigación.....	7
Tabla 2 Indicadores e Instrumentos.	8
Tabla 3 Matriz de Operacionalización de Variables	12
Tabla 4 Matriz de Consistencia	14
Tabla 5 Resumen de antecedentes de la investigación	19
Tabla 6 Principales aportes y resultados del estado del arte	33
Tabla 7 Técnicas e Instrumentos de Recolección de Datos.....	50
Tabla 8 Roles definidos	61
Tabla 9 Cronograma general de los sprints	62
Tabla 10 Requerimientos Funcionales del Sistema	65
Tabla 11 Requerimientos No Funcionales del Sistema.....	68
Tabla 12 Casos de uso identificados.....	75
Tabla 13 Caso de Uso CU-01	76
Tabla 14 <i>Caso de Uso CU-02</i>	78
Tabla 15 <i>Caso de Uso CU-03</i>	80
Tabla 16 <i>Caso de Uso CU-04</i>	82
Tabla 17 Caso de Uso CU-05	84
Tabla 18 <i>Caso de Uso CU-06</i>.....	86
Tabla 19 <i>Caso de Uso CU-07</i>	87
Tabla 20 Caso de Uso CU-08	89
Tabla 21 Resultados Sprint 1.....	96
Tabla 22 Resultados Sprint 2.....	100
Tabla 23 Resultados Sprint 3.....	107
Tabla 24 Resultados de las pruebas unitarias.....	108

Tabla 25 Escenarios de Validación..... 109

Tabla 26 Costos estimados de implementación y operación.....111

Tabla 27 Estimación de duración y consumo de la API según el nivel de uso111



ÍNDICE DE FIGURAS

Figura 1 Marco del sistema LLM Integrado con Power BI	39
Figura 2 Diagrama de flujo de la Integración de Power BI	40
Figura 3 Diagrama de Gantt - Cronograma de Actividades del Plan de Tesis	55
Figura 4 Arquitectura general del sistema propuesto.....	70
Figura 5 Diagrama de flujo del proceso de consulta.....	73
Figura 6 Diagrama Caso de Uso CU-01	77
Figura 7 Diagrama Caso de Uso CU-02	79
Figura 8 Diagrama Caso de Uso CU-03	81
Figura 9 Diagrama Caso de Uso CU-04	83
Figura 10 Diagrama Caso de Uso CU-05	85
Figura 11 Diagrama Caso de Uso CU-06	86
Figura 12 Diagrama Caso de Uso CU-07	88
Figura 13 Diagrama Caso de Uso CU-08	90
Figura 14 Boceto de la interfaz del chatbot – Inicio de conversación.	91
Figura 15 Boceto de la interfaz del chatbot – Ejemplo de consulta exitosa.....	92
Figura 16 Boceto de la interfaz del chatbot – Manejo de error o excepción.....	93
Figura 17 Estructura de la base de datos en SQL Server.	94
Figura 18 Código de conexión entre Python y SQL Server.	95
Figura 19 Conexión exitosa al servidor SQL Server.	95
Figura 20 Función para generar consultas dinámicas.....	97
Figura 21 Función de limpieza de consultas SQL generadas.	98
Figura 22 Ejecución de la consulta SQL y procesamiento de resultados.....	99
Figura 23 Persistencia de contexto e interacción con el modelo LLM.	100
Figura 24 Interfaz inicial del chatbot desplegado en entorno local.....	102

Figura 25 Chatbot procesando una consulta en lenguaje natural.	103
Figura 26 Respuesta generada por el chatbot a la consulta SQL.	104
Figura 27 Ejecución de la consulta SQL en el entorno de desarrollo.	105
Figura 28 Persistencia conversacional en consultas encadenadas.	106
Figura 29 Conjunto de datos recopilados para el análisis Post-Test 116	116
Figura 30 Conjunto de datos recopilados para el análisis Pre-Test..... 116	116
Figura 31 Comparación de puntajes promedio Pre-Test y Post-Test. 117	117
Figura 32 Correlación Spearman 118	118
Figura 33 Resultados de la prueba t pareada Pre-Test vs Post-Test..... 119	119
Figura 34 Prueba de Shapiro–Wilk 120	120
Figura 35 Cálculo de d de Cohen 121	121
Figura 36 Procedimiento de validación estadística global en Python..... 122	122
Figura 37 Encuesta Pre-Test Parte 1 142	142
Figura 38 Encuesta Pre-Test Parte 2 143	143
Figura 39 Encuesta Post-Test Parte 1 144	144
Figura 40 Encuesta Post-Test Parte 2 145	145
Figura 41 Conjunto de Datos de la Investigación – Pre-Test 146	146
Figura 42 Conjunto de Datos de la Investigación – Post-Test 147	147

INTRODUCCIÓN

En la actualidad, el avance tecnológico ha transformado significativamente la manera en que las organizaciones gestionan sus procesos internos y toman decisiones estratégicas. En un entorno altamente competitivo y dinámico, las empresas se ven en la necesidad de adoptar herramientas innovadoras que les permitan optimizar su rendimiento y mejorar su capacidad de respuesta ante los constantes cambios del mercado. En este contexto, la integración de modelos de inteligencia artificial con herramientas de análisis empresarial representa una alternativa eficaz para fortalecer la toma de decisiones basadas en datos.

Las empresas generan volúmenes crecientes de información provenientes de múltiples fuentes, lo que plantea un desafío en la recopilación, procesamiento y análisis de estos datos de manera eficiente y oportuna. Sin embargo, la dependencia de métodos tradicionales de análisis, caracterizados por procesos manuales y subjetivos, limita la capacidad de los responsables de la toma de decisiones para anticipar tendencias, identificar patrones y mitigar riesgos. Ante esta problemática, la implementación de modelos de inteligencia artificial, capaces de procesar grandes conjuntos de datos con precisión, permite transformar la información en conocimiento accionable, facilitando la formulación de estrategias más acertadas.

La presente investigación aborda la integración de modelos de inteligencia artificial para mejorar la toma de decisiones empresariales. Se busca demostrar cómo esta sinergia tecnológica puede optimizar los procesos analíticos, proporcionando a las organizaciones herramientas más robustas para la interpretación de datos y la generación de *insights* estratégicos.

Capítulo I: Planteamiento del Problema: Se expone el contexto de la problemática abordada, definiendo el enunciado del problema, su formulación general y específica, la justificación, los objetivos de estudio, así como los alcances y limitaciones del trabajo.

Capítulo II: Marco Teórico: Se presentan los antecedentes de investigaciones previas relacionadas con la temática, además de las bases teóricas que sustentan el estudio, incluyendo conceptos fundamentales sobre inteligencia artificial.

Capítulo III: Metodología: Se describe el enfoque metodológico de la investigación, detallando el tipo, nivel y diseño de estudio. Además, se especifica la población y muestra de análisis, junto con las técnicas utilizadas para la recolección y procesamiento de datos.

Capítulo IV: Desarrollo de la Solución Tecnológica. Detalla el diseño, arquitectura, requerimientos funcionales y no funcionales, la metodología SCRUM utilizada, los casos de uso, la interfaz del *chatbot* y los resultados de las pruebas técnicas.

Capítulo V: Resultados. Presenta el análisis descriptivo e inferencial de los datos, la evaluación del impacto del sistema y la validación de las hipótesis de investigación.



CAPÍTULO I

1. PLANTEAMIENTO DE LA INVESTIGACION

1.1. Planteamiento del Problema:

A nivel global, las micro y pequeñas empresas enfrentan serias dificultades para gestionar sus inventarios de forma eficiente debido a limitaciones tecnológicas, falta de digitalización y dependencia de métodos tradicionales. Según la OECD (2024), el 67% de las MYPES en América Latina no cuentan con herramientas digitales avanzadas para analizar su información, lo que genera ineficiencias operativas, esta problemática también afecta directamente a la región sur.

En Arequipa, en muchas micro y pequeñas empresas (MYPES) se registra dificultades continuadas en el manejo de sus inventarios, influyendo negativamente en la toma de decisiones. La ausencia de herramientas tecnológicas para procesar los datos y la puntual accesibilidad a la información producen situaciones de escasez o de abundancia de los productos, lo cual repercute negativamente en la rentabilidad, la operatividad y la satisfacción del cliente (Pérez Díaz, 2022).

El problema radica principalmente en el uso de sistemas tradicionales, la integración deficiente de datos y la falta de conocimiento sobre herramientas modernas como los modelos de Inteligencia Artificial (IA) (Figueroa Rivera & Reyes Canales, 2022). Hoy en día se ha demostrado que el empleo de modelos basados en IA puede mejorar significativamente la gestión de inventarios, facilitando el análisis de la información y respaldando una toma de decisiones más eficiente (Galarreta, 2019).

A pesar de estos avances, muchas MYPES de Arequipa siguen tomando decisiones de compra y reposición basadas en intuición o experiencia, sin ningún tipo de respaldo en datos históricos (Zavaleta Castro et al., 2024). Esto ocurre en un contexto de transformación digital desigual, donde las empresas pequeñas tienen mayores limitaciones para adoptar las nuevas tecnologías (Microsoft News Center Latinoamérica, 2023).

Como resultado de esta brecha tecnológica y analítica, las MYPES enfrentan altos costos operativos, pérdidas financieras, baja competitividad frente a empresas más tecnificadas y menor fidelización de clientes (Ministerio de la Producción, 2023).

La falta de una visualización clara la información limita la capacidad de respuesta a cambios en la demanda, especialmente en un entorno económicos inestable (Buendía Bejarano, 2024).

Considerando esta problemática, se propone desarrollar un sistema de apoyo a la decisión basado en inteligencia artificial, que permita a las MYPES comerciales de Arequipa acceder, consultar y analizar información histórica y actual de sus inventarios para mejorar su gestión operativa y fortalecer su competitividad local.

1.2. Objetivos de la Investigación

1.2.1. Objetivo General

Desarrollar un sistema de apoyo a la toma de decisiones para la gestión de inventarios mediante la aplicación de modelos de lenguaje de gran escala o *Large Language Models* (LLM) para apoyar los procesos comerciales de las MYPES en Arequipa.

1.2.2. Objetivos Específicos

1. Diagnosticar las fallas existentes en la toma de decisiones y gestión de inventarios en MYPES comerciales de Arequipa.
2. Analizar los impactos operativos y económicos generados por la falta de abastecimiento y por el exceso de *stock* de productos.
3. Diseñar un *chatbot* basado en modelos de lenguaje de gran escala (LLM) que sirva como herramienta de apoyo a la toma de decisiones en la gestión de inventarios.
4. Evaluar la efectividad del sistema propuesto en el apoyo a la toma de decisiones para la gestión de inventarios de las MYPES comerciales de Arequipa, mediante la

comparación de los resultados obtenidos en el *Pre-Test* y *Post-Test* y la aplicación de pruebas estadísticas inferenciales.

1.3. Preguntas de Investigación:

- ¿Cómo mejorar la toma de decisiones en la gestión de inventarios de las MYPES mediante LLM?
- ¿Qué deficiencias presentan actualmente las MYPES comerciales de Arequipa en su gestión de inventarios y toma de decisiones?
- ¿Cuáles son los principales impactos económicos y operativos del desabastecimiento y *sobrestock* en estas empresas?
- ¿Cómo puede diseñarse un *chatbot* basado en modelos de lenguaje de gran escala (LLM) para ser una herramienta de apoyo a la toma de decisiones en la gestión de inventarios?
- ¿Qué tan efectivo resulta el sistema propuesto como herramienta de apoyo a la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa?

1.4. Formulación de la Hipótesis, Variables, Indicadores:

Hipótesis General

- **H₀ (Hipótesis Nula):**

La implementación de un chatbot basado en modelos de lenguaje de gran escala (LLM) no influye en la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.

- **H₁ (Hipótesis Alternativa):**

La implementación de un chatbot basado en modelos de lenguaje de gran escala (LLM) sirve para apoyar y mejorar la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.

En la Tabla 1 se presentan las variables de estudio, junto con su definición conceptual y operacional, correspondientes a la hipótesis planteada.

Tabla 1
Variables de Investigación

Tipo	Nombre de la Variable	Definición Conceptual	Definición Operacional
Independiente	Aplicación de LLM	Uso de modelos de lenguaje de gran escala (LLM) para procesar y presentar datos	Desarrollo e implementación de un <i>chatbot</i> basado en LLM que permite realizar consultas sobre inventario en lenguaje natural y obtener respuestas automáticas que apoyan la toma de decisiones.
Dependiente	Toma de decisiones en la gestión de inventarios	Proceso mediante el cual las MYPES de planifican, reponen y controlan su inventario	Evaluación de la mejora percibida en la toma de decisiones de inventario mediante la comparación entre el <i>Pre-test</i> y el <i>Post-test</i> .

Nota. Elaboración Propia

En la Tabla 2 se presentan los indicadores e instrumentos utilizados para evaluar las variables del estudio, tanto para la aplicación del LLM como para la toma de decisiones en la gestión de inventarios.

Indicadores e Instrumentos (para evaluar las variables)

Tabla 2

Indicadores e Instrumentos.

Variable	Indicador	Instrumento de Recolección
Aplicación de LLM	Nivel de implementación del sistema	Lista de verificación / Validación técnica
	Frecuencia de uso del <i>chatbot</i>	Registro de uso del sistema (log del sistema)
	Número de funciones integradas	Documentación técnica del sistema
Toma de decisiones en inventarios	Variación del puntaje promedio entre <i>Pre-Test</i> y <i>Post-Test</i>	Cuestionario <i>Pre-Test</i> y <i>Post-Test</i> / Escala Likert
	Significancia estadística de la diferencia entre ambas mediciones	Resultados del análisis estadístico inferencial
	Nivel de satisfacción y utilidad percibida del sistema	Cuestionario <i>Post-Test</i> / Escala Likert

Nota. Elaboración Propia

1.5. Línea y Sub-línea de Investigación a la que corresponde el Problema

- **Línea de Investigación:** Inteligencia Artificial
- **Sub-línea de Investigación:** Inteligencia Artificial aplicada

Esta línea permite abordar la aplicación práctica de modelos LLM en entornos reales, como el caso de las MYPES comerciales en Arequipa, con el propósito de apoyar la toma de decisiones en la gestión de inventarios mediante el uso de asistentes conversacionales inteligentes.

1.6. Palabras Clave

Modelos de Lenguaje de Gran Escala, Toma de decisiones, Gestión de inventarios.

1.7. Solución Propuesta.

1.7.1. Justificación e Importancia.

En un contexto donde las MYPES enfrentan limitaciones técnicas, operativas y de formación para gestionar adecuadamente sus inventarios, resulta fundamental ofrecer soluciones accesibles y de fácil adopción que faciliten el acceso a la información y apoyen la toma de decisiones. La propuesta de implementar un chatbot basado en modelos de lenguaje LLM busca reducir la dependencia de análisis manual y decisiones empíricas, permitiendo a las MYPES acceder de manera más ágil y comprensible a la información relacionada con sus inventarios. Esta solución tiene importancia no solo técnica, sino también práctica y social, ya que democratiza el acceso a la inteligencia artificial aplicada y promueve la transformación digital en pequeñas empresas, un sector vital para la economía local. Además, ofrece una alternativa intuitiva que facilita la interacción con la información del inventario sin requerir conocimientos avanzados en análisis de datos.

1.7.2. Descripción de la Solución

La solución consiste en el desarrollo de un sistema de apoyo a la toma de decisiones para la gestión de inventarios, que combina dos componentes clave:

1. Modelo de Lenguaje de Gran Escala (LLM):

Permitirá interpretar consultas en lenguaje natural relacionadas con la información de inventarios y generar respuestas comprensibles para los usuarios, facilitando el acceso y análisis de los datos disponibles.

2. Chatbot inteligente:

Será el punto de interacción con el usuario, permitiendo a los responsables de las MYPES consultar en lenguaje natural datos clave como:

¿Cuál fue el producto más vendido en enero? ¿Cuál fue el producto menos vendido en enero? ¿Qué productos presentan menor *stock* registrado? Etc.

1.7.3. Aporte

El principal aporte de esta investigación es el desarrollo de un sistema conversacional basado en modelos de lenguaje de gran escala (LLM), que:

- Incorpora IA avanzada y modelos de lenguaje de gran escala (LLM) al entorno empresarial MYPE, donde normalmente no se accede a estas tecnologías.
- Facilita la toma de decisiones basada en datos, reduciendo errores humanos y decisiones subjetivas.
- Promueve la adopción tecnológica sin necesidad de personal experto, mediante una interfaz conversacional intuitiva.
- Mejora la eficiencia operativa de las MYPES, al reducir el riesgo de quiebre de *stock*, sobrecostos y pérdida de ventas.

Este enfoque puede ser escalado a otros procesos empresariales o incluso adaptado a otros sectores, siendo un modelo replicable para fomentar la transformación digital a nivel local.

1.7.4. Matriz de Operacionalización de Variables

En todo tipo de investigación el definir con precisión las variables es importante para el diseño metodológico puesto que permite traducir el problema en elementos medibles, en esta tesis orientada al desarrollo de un sistema de apoyo a la toma de decisiones mediante la integración de modelos de lenguaje de gran escala (LLM).

La matriz de operacionalización, en este sentido, facilita la recolección y el análisis de datos de manera ordenada y coherente con los objetivos planteados, al establecer la relación entre las variables de estudio, sus dimensiones, indicadores y métodos de medición.

Se identificaron tanto la variable dependiente como la independientes, incluyendo también las variables intervinientes e inesperadas que influirían en nuestros resultados a obtener.

La variable independiente es la “Aplicación de modelos de lenguaje de gran escala (LLM)”, esta representa el eje tecnológico de la tesis y que para un mejor análisis de esta se descompuso en dimensiones como la implementación tecnológica, el apoyo a la toma de decisiones y la interacción conversacional que todas ellas son medibles mediante técnicas de desarrollo y evaluación de software.

Su medición se centra en validar el funcionamiento del sistema propuesto, tomando en cuenta la integración del modelo LLM con la base de datos, la generación de consultas en lenguaje SQL y la habilidad del *chatbot* para responder a preguntas sobre inventarios.

Por otro lado, la variable dependiente es la, “Toma de decisiones en la gestión de inventarios”, que representa los resultados esperados a mejorar en base a la aplicación nuestro sistema propuesto, y que de la misma forma que la variable independiente también se dividió en dimensiones como la mejora percibida en la gestión de inventarios, efectividad estadística del sistema y Satisfacción y utilidad percibida.

También se han considerado una variable interviniente como es el nivel de alfabetización digital de los usuarios, y una variable inesperada que es los cambios en la demanda del mercado, ambas se incluyeron en la matriz para garantizar un mejor análisis e identificar factores externos que podrían intervenir en el funcionamiento del sistema o en la adopción de la propuesta por parte de los interesados.

A continuación, en la Tabla 3 se presenta la matriz de operacionalización de variables, donde se detallan las dimensiones, indicadores y métodos de medición correspondientes a cada tipo de variable definida en la investigación.

Matriz de Operacionalización de Variables

Tabla 3

Matriz de Operacionalización de Variables

Tipo de Variable	Nombre de la Variable	Dimensión	Indicador	Método de Medición	Notas
Independiente	Aplicación de modelos de lenguaje de gran escala (LLM)	Implementación tecnológica	Grado de implementación del sistema integrado LLM	Validación funcional del sistema / documentación técnica	Se verifica que el sistema funcione correctamente con sus componentes principales.
		Apoyo a la toma de decisiones	Nivel de precisión y coherencia de las respuestas del <i>chatbot</i>	Evaluación de usabilidad / encuesta <i>Post-Test</i> a usuarios	Se mide la utilidad percibida del <i>chatbot</i> como herramienta de apoyo.
		Interfaz conversacional	Porcentaje de respuestas relevantes del <i>chatbot</i>	Prueba controlada con consultas frecuentes	El <i>chatbot</i> debe responder correctamente a consultas sobre inventario
Dependiente	Toma de decisiones en inventarios	Mejora percibida en la gestión de inventarios	Variación del puntaje promedio entre <i>Pre-Test</i> y <i>Post-Test</i>	Cuestionario <i>Pre-Test</i> y <i>Post-Test</i> / Escala Likert	Se mide la diferencia entre los puntajes antes y después del uso del sistema.
		Efectividad estadística del sistema	Significancia estadística de la diferencia entre ambas mediciones	Análisis estadístico inferencial	Se evalúa mediante la prueba de normalidad y la prueba t para muestras relacionadas.
		Satisfacción y utilidad percibida	Nivel de satisfacción y utilidad percibida del sistema	Cuestionario <i>Post-Test</i> / Escala Likert	Evalúa la aceptación del <i>chatbot</i> como herramienta de apoyo a la toma de decisiones.
Interviniente	Nivel de alfabetización digital	Uso de herramientas TIC	Grado de familiaridad con herramientas TIC y sistemas de IA	Encuesta técnica o rúbrica de competencias	Afecta la adopción del sistema propuesto
Inesperada	Cambios en la demanda del mercado	Variabilidad de consumo	Fluctuaciones imprevistas en la demanda	Datos históricos vs. comportamiento actual	Puede influir en el uso del sistema y en la toma de decisiones de inventario

Nota. Elaboración Propia

1.7.5. Matriz de Consistencia

La matriz de consistencia es un instrumento fundamental dentro del marco metodológico de toda investigación científica, ya que permite asegurar la coherencia interna entre los elementos centrales del estudio.

En el caso de esta tesis, orientada al diseño de un sistema de apoyo a la toma de decisiones mediante el uso de modelos de lenguaje de gran escala (LLM), la matriz ha sido construida con base en el problema de investigación, los objetivos (general y específicos), la hipótesis, las variables involucradas, la metodología empleada y la población objeto de estudio.

Este instrumento permite verificar que cada componente del trabajo esté debidamente alineado, desde el planteamiento del problema hasta la definición de los indicadores que permitirán medir el impacto de la propuesta. La variable independiente, correspondiente a la implementación del sistema basado en LLM, se relaciona directamente con la variable dependiente, que es la mejora en la toma de decisiones en la gestión de inventarios por parte de las MYPES del sector comercial.

Además, se han definido claramente los objetivos específicos y sus respectivas hipótesis, así como las técnicas de recolección de datos que se emplearán en el estudio. Con ello, se busca establecer una ruta metodológica sólida, verificable y replicable en otros contextos similares dentro del ámbito de la Ingeniería de Sistemas.

La siguiente matriz que se muestra en la Tabla 4 servirá como hoja de ruta para el desarrollo de la investigación, y facilitará el análisis de resultados, la validación de la hipótesis y la argumentación de las conclusiones al término del estudio.

MATRIZ DE CONSISTENCIA

Tabla 4
Matriz de Consistencia

Problema de Investigación	Objetivos	Hipótesis	Variables e Indicadores	Metodología	Población y Muestra
<p>¿Cómo influye la aplicación de modelos de lenguaje de gran escala integrados en la toma de decisiones sobre gestión de inventarios en micro y pequeñas empresas comerciales de Arequipa?</p> <p>Problemas específicos:</p> <ul style="list-style-type: none"> • ¿Qué deficiencias existen en los procesos actuales de gestión de inventarios? • ¿Qué efectos tienen el desabastecimiento y <i>sobrestock</i> en las MYPES? • ¿Cómo puede diseñarse un <i>chatbot</i> basado en modelos de lenguaje de gran escala (LLM) que sirva como herramienta de apoyo a la toma de decisiones? • ¿Qué tan efectivo resulta el sistema propuesto como apoyo a la toma de decisiones de inventario? 	<p>Objetivo General: Desarrollar un sistema de apoyo a la toma de decisiones en la gestión de inventarios mediante la aplicación de modelos de lenguaje de gran escala, orientado a las MYPES comerciales de Arequipa</p> <p>Objetivos Específicos:</p> <ol style="list-style-type: none"> 1. Diagnosticar las deficiencias actuales en los procesos de toma de decisiones. 2. Analizar los impactos del desabastecimiento y <i>sobrestock</i>. 3. Diseñar un <i>chatbot</i> basado en modelos de lenguaje de gran escala (LLM) que sirva como herramienta de apoyo a la toma de decisiones en la gestión de inventarios. 4. Evaluar la efectividad del sistema propuesto mediante la comparación <i>Pre-Test-Post-Test</i> y pruebas estadísticas inferenciales. 	<p>Hipótesis General: La implementación de un <i>chatbot</i> basado en modelos de lenguaje de gran escala (LLM) sirve para apoyar y mejorar la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.</p> <p>Hipótesis Nula (H₀): La implementación de un <i>chatbot</i> basado en modelos de lenguaje de gran escala (LLM) no influye en la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.</p> <p>Hipótesis Alternativa (H₁): La implementación de un <i>chatbot</i> basado en modelos de lenguaje de gran escala (LLM) sirve para apoyar y mejorar la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.</p>	<p>Variable Independiente (V1): Aplicación de modelos LLM</p> <p>Indicadores:</p> <ul style="list-style-type: none"> • Nivel de implementación del sistema • Frecuencia de uso • N.º de funciones integradas del sistema <p>Variable Dependiente (V2): Toma de decisiones en gestión de inventarios.</p> <p>Indicadores:</p> <ul style="list-style-type: none"> • Variación del puntaje promedio entre <i>Pre-Test</i> y <i>Post-Test</i>. • Significancia estadística de la diferencia entre ambas mediciones • Nivel de satisfacción y utilidad percibida del sistema 	<p>Tipo de investigación: Aplicada y tecnológica</p> <p>Nivel: Descriptiva y explicativa</p> <p>Diseño: Pre-experimental de un solo grupo con <i>Pre-Test</i> y <i>Post-Test</i>.</p> <p>Técnicas: Encuestas, revisión documental</p> <p>Instrumentos: Cuestionarios estructurados <i>Pre-Test</i> y <i>Post-Test</i>, y registros de uso del sistema.</p>	<p>Población: MYPES del sector comercial en Arequipa</p> <p>Muestra: 40 empresas seleccionadas por muestreo intencionado</p> <p>Técnicas de selección: Acceso a datos históricos, disposición a participar y cumplir criterios tecnológicos mínimos</p> <p>Instrumentos: Encuestas estructuradas (<i>Pre-Test</i> y <i>Post-Test</i>) y registros de uso del sistema.</p>

Nota. Elaboración Propia



CAPÍTULO II

2. FUNDAMENTOS TEÓRICOS

2.1. Antecedentes de la Investigación

Uno de los pilares fundamentales para sustentar cualquier investigación es el análisis de estudios previos que abordan temáticas similares o relacionadas.

En el caso de la presente tesis, se ha identificado una serie de trabajos académicos y científicos que aportan perspectivas relevantes sobre la aplicación de inteligencia artificial en la gestión de inventarios, el uso de modelos de lenguaje de gran escala (LLM) y similares para la toma de decisiones, especialmente en contextos empresariales.

Albayrak Ünal et al. (2023), en su artículo *Applications of Artificial Intelligence in Inventory Management: A Systematic Review of the Literature*, realizaron una revisión sistemática de 59 estudios científicos que abordan el uso de IA en la gestión de inventarios.

El análisis abarca aplicaciones entre 2012 y 2022, demostrando cómo los algoritmos inteligentes pueden optimizar procesos logísticos, reducir sobrecostos y predecir necesidades de reabastecimiento, estableciendo una base teórica sólida para investigaciones aplicadas en este campo.

Aktepe et al. (2021), en su estudio *Demand forecasting application with regression and artificial intelligence methods in a construction machinery company.*, examinaron el potencial de los modelos de regresión y de inteligencia artificial para pronosticar la demanda en una empresa de maquinaria. Con ese fin, se valieron de los datos de ventas históricos. Los resultados muestran que este tipo de modelos facilitan una mejor previsión de la demanda y una planificación de las operaciones más eficiente.

Alfaro Pareja et al. (2023), en su tesis *Proceso S&OP: Diseño de modelos predictivos de demanda y cuadro de mando para la gestión eficiente del inventario*, plantearon la utilización de *dashboards* interconectados con modelos predictivos en una empresa importadora. Esta herramienta te permite ver los indicadores más importantes del inventario en

tiempo real, facilitando que puedas tomar decisiones más rápidas y mejor sustentadas. El porqué de este trabajo es importante, porque muestra cómo la tecnología puede ayudar de manera práctica a la gestión de inventarios.

Condori et al. (2024), en *The Use of Python in AI and Its Impact on Inventory Management in America 2023*, estudió cómo el empleo de bibliotecas de Python aplicadas a inteligencia artificial puede mejorar la gestión de inventarios en empresas de América Latina. En su investigación, se destacan casos en los que estas herramientas permiten automatizar tareas, predecir el consumo y disminuir los errores cometidos por las personas.

Dhaliwal et al. (2023), en *A detailed Analysis of Use of AI in Inventory Management for technically better management*, estudiaron cómo la inteligencia artificial puede influir en la gestión de inventarios y en la rentabilidad de las empresas. Los autores señalan que estas tecnologías facilitan la eficiencia del trabajo y la toma de decisiones con información mejorada.

Eldred et al. (2023), con el estudio *Leveraging AI for Inventory Management and Accurate Forecast-An Industrial Field Study*, usaron modelos de predicción con datos reales de una compañía del sector energético. El estudio demostró que estos modelos pueden incrementar la precisión de las previsiones y disminuir las pérdidas que generan el manejo erróneo de inventarios.

Eraslan & Iç. (2020), desarrollaron un artículo llamado *An improved decision support system for ABC inventory classification*, crearon un sistema de apoyo a la toma de decisiones para clasificar inventarios utilizando el método ABC. Para ello emplearon técnicas de inteligencia artificial que permiten ordenar de forma automática los productos, identificar los más importantes y aprovechar mejor los recursos disponibles.

Hristov et al. (2022), en *Artificial Intelligence Systems for Warehouses Stocks Control*, proponen sistemas autónomos basados en inteligencia artificial para el control de inventarios en almacenes. Su propuesta se basa en el uso de hardware económico y visión computacional,

por lo que podría ser de utilidad para empresas con escasos recursos tecnológicos, como es el caso de muchas MYPES.

Ines et al. (2024), en *The Role of AI in Enhancing Decision-Making in Small and Medium Enterprises (SMEs)*, los resultados demuestran que la inteligencia artificial puede hacer más eficiente la actividad operativa y la toma de decisiones, sobre todo si se adapta a la realidad y necesidades de cada empresa.

Patil et al. (2024), en *Development of MS Excel and Power BI Integrated Production Scheduling System for an MSME*, incorporaron Power BI a un sistema de programación de producción para una pequeña empresa. El estudio indica que esta herramienta permite una mejor visualización de los datos y facilita la planificación de las operaciones.

Preil & Krapp, (2022), en *Artificial intelligence-based inventory management: a Monte Carlo tree search approach*, propusieron un sistema de predicción de inventarios usando búsqueda de árbol Monte Carlo. En simulaciones, este método ayudó a disminuir el efecto látigo (*bullwhip effect*) y a mejorar la precisión en los pedidos.

Saraogi et al. (2019), con *An Un-Supervised Approach for Backorder Prediction Using Deep Autoencoder*, examinaron el empleo de modelos no supervisados para predecir los quiebres de inventario. Su trabajo de investigación se apoya en técnicas avanzadas de *deep learning* que permiten identificar comportamientos extraños o anomalías en los datos históricos del inventario.

Sathyabama et al. (2024), en *AI-Driven Expiry Prediction and Dynamic Pricing System for Retail Inventory Management Utilizing ARIMA and LSTM Models*, mostraron que la combinación de modelos estadísticos con redes neuronales puede ayudar a mejorar la gestión del inventario. Su propuesta gira en torno a la predicción de fechas de vencimiento y al ajuste dinámico de precios en el sector *retail*.

En líneas generales, estos antecedentes sirven como base a la presente investigación, ya que demuestran que la inteligencia artificial, los modelos predictivos, los dashboards y otros sistemas automatizados pueden mejorar de forma clara la gestión de inventarios.

Asimismo, estos estudios son útiles para el caso de las MYPES de Arequipa, donde es importante aprovechar bien los recursos, reducir errores y tomar decisiones de manera oportuna.

En la Tabla 5 se exponen los autores, el enfoque de cada estudio y su mayor contribución en torno a la gestión de inventarios y el empleo de la inteligencia artificial, con el fin de resumir los principales hallazgos de los trabajos revisados.

Tabla 5
Resumen de antecedentes de la investigación

Autor y año	Tipo de estudio	Enfoque	Principal aporte
Albayrak et al. (2023)	Ünal Revisión sistemática	IA en inventarios	Demuestra que la IA optimiza procesos logísticos y predicción de demanda
Aktepe et al. (2021)	Experimental	Predicción de demanda	Evidencia la eficacia de modelos de IA en planificación operativa
Alfaro Pareja et al. (2023)	Tesis aplicada	Modelos predictivos	Integración de dashboards para mejorar gestión de inventarios
Condori et al. (2024)	Análisis aplicado	Python e IA	Automatización y reducción de errores en inventarios
Dhaliwal et al. (2023)	Estudio analítico	IA en inventarios	Impacto positivo en rentabilidad y toma de decisiones

Tabla 5 (Continuación)

Autor y año	Tipo de estudio	Enfoque	Principal aporte
Eldred et al. (2023)	Estudio de campo	Predicción con IA	Mejora en exactitud de pronósticos
Eraslan & Iç. (2020)	Desarrollo de sistema	Clasificación ABC	Optimización de inventarios mediante IA
Hristov et al. (2022)	Propuesta tecnológica	Control de inventarios	Sistemas autónomos accesibles para MYPES
Ines et al. (2024)	Estudio cuantitativo	IA en PYMES	Mejora significativa en toma de decisiones
Patil et al. (2024)	Aplicación tecnológica	Power BI	Mejora en visualización y planificación
Preil & Krapp, (2022)	Simulación	Predicción inventarios	Reducción del efecto látigo
Saraogi et al. (2019)	Deep Learning	Predicción de <i>stock</i>	Detección de anomalías y quiebres
Sathyabama et al. (2024)	Modelos híbridos	ARIMA + LSTM	Optimización de inventario y precios

Nota. Elaboración Propia

2.2. Estado del arte

En los últimos cinco años, la ingeniería de sistemas ha crecido mucho en el uso de la inteligencia artificial (IA), sobre todo en la gestión de inventarios y en la toma de decisiones de las MYPES. A continuación, se exponen los estudios más relevantes y recientes (2019-2024), los cuales sirven de sustento para contextualizar y justificar la investigación actual.

En el estudio realizado por Aktepe et al. (2021), *Demand Forecasting Application with Regression and Artificial Intelligence Methods in a Construction Machinery Company*, se evaluaron los modelos de regresión y de IA para predecir la demanda en maquinaria de construcción. Si bien el sector es diferente, la estructura del modelo es fácilmente adaptable a las MYPES comerciales.

En el estudio realizado por Akter et al. (2025), *Integration of advanced Artificial Intelligence in Supply Chain Management, its Challenges and Opportunities*, trataron los desafíos de la integración avanzada de IA en la cadena de suministro. Dan una visión integral de los aspectos técnicos y estratégicos que intervienen en dicha transformación.

De acuerdo con la investigación de Albayrak Ünal et al. (2023), en *Applications of Artificial Intelligence in Inventory Management: A Systematic Review of the Literature*, se hizo una revisión sistemática de 59 artículos de IA aplicada a inventarios, identificando los enfoques, modelos y resultados. Este compendio proporciona una base sólida de evidencia científica reciente.

De acuerdo con la investigación de Alfaro Pareja et al. (2023), en *Proceso S&OP: Diseño de Modelos Predictivos de Demanda y Cuadro de Mando para la Gestión Eficiente del Inventario en Empresa Importadora y Distribuidora*, en Perú se desarrolló una tesis en la que se integraron modelos predictivos con Power BI en una empresa importadora. Su aplicación práctica muestra que es posible y efectivo unir inteligencia artificial y visualización de datos.

Según Ayinaddis (2025), en *Artificial intelligence adoption dynamics and knowledge in SMEs and large firms: A systematic review and bibliometric analysis*, se realizó una revisión sistemática de 78 estudios sobre adopción de IA en empresas pequeñas y grandes, que permitió identificar 10 dimensiones clave (p. ej. preparación tecnológica, competencias, presión del mercado, personalización, datos, entre otros) que permiten entender la diferencia existente entre las PYMES y las empresas grandes.

Este estudio muestra que, si bien la inteligencia artificial se está convirtiendo en una prioridad tecnológica mundial, las MYPES necesitan enfoques adaptados a su capacidad financiera, técnica y organizativa para poder utilizar estas tecnologías con éxito. Este descubrimiento resulta de mucha importancia para la tesis, pues confirma la necesidad de diseñar soluciones basadas en LLM que sean accesibles y viables para las MYPES de Arequipa.

Barragán Ramírez et al. (2025), en *Inteligencia de negocios para gestión de inventarios en las empresas importadoras de estructurales de calzado*, mediante un estudio cuantitativo a 9 empresas importadoras de Ambato (Ecuador), constataron que existe una baja adopción de herramientas de inteligencia de negocios para la gestión de inventarios, pese a que los empresarios reconocen los beneficios operativos y financieros asociados como mejoras en eficiencia, reducción de costos y aumento de rentabilidad. Este resultado respalda la tesis al mostrar que hay un vacío en la adopción de tecnología, el cual puede ser cubierto con prototipos de IA aplicables a MYPES locales.

Según la investigación de Carayannis et al. (2025), en *Enhancing SME Resilience through Artificial Intelligence and Strategic Foresight: A Framework for Sustainable Competitiveness*, se propuso un marco estratégico que relaciona la Inteligencia Artificial (IA) y la prospectiva con las PYMES. Los autores resaltan el valor de la IA y la previsión más allá de lo operativo. Esto le añade también algo de valor a la competitividad sostenible de las PYMES.

En el estudio de Condori et al. (2024), *The Use of Python in AI and Its Impact on Inventory Management in America 2023*, se analiza el cómo las bibliotecas de Python aplicadas a la IA pueden transformar la gestión de inventarios en empresas latinoamericanas, destacando casos de automatización, predicción de consumo y reducción de errores humanos.

Según Cortez-Vásquez & García Conde (2024), en *La Inteligencia Artificial y sus implicancias en el Control Interno y la Gestión de los Inventarios*, mediante un estudio

descriptivo, la IA transforma significativamente el control interno y la gestión de inventarios en las organizaciones modernas, facilitando la identificación de patrones y anomalías, mejorando la trazabilidad desde el origen hasta el destino del producto y permitiendo generar recomendaciones predictivas automatizadas para optimizar inventarios, lo cual contribuye a la eficiencia operativa y financiera.

Este aporte es importante para mi tesis, ya que confirma que el uso de la IA en los inventarios no solo optimiza procesos, sino que también fortalece la fiabilidad de la información en MYPES.

De acuerdo con Daios et al. (2025), en *AI Applications in Supply Chain Management: A Survey* proporciona un análisis detallado de las aplicaciones de la inteligencia artificial en los principales procesos de la cadena de suministro, incluyendo la gestión de inventarios, la predicción de la demanda, el transporte, las compras, la resiliencia y la gestión de riesgos. El estudio destaca cómo el empleo de la IA en el ámbito de la Industria 4.0, no solo mejora la eficiencia operativa, sino que también potencia la capacidad estratégica, la resiliencia ante las interrupciones y la toma de decisiones basada en datos, elementos esenciales para las MYPES que buscan modernizar sus procesos logísticos. Es importante para la tesis, ya que respalda la inclusión de la IA como un factor estratégico de competitividad de las MYPES.

En el estudio de Dhaliwal et al. (2023), en *A Detailed Analysis of Use of AI in Inventory Management for Technically Better Management*, se hizo un análisis técnico sobre el uso de IA en la gestión de inventarios. Su propuesta incluyó la identificación de barreras tecnológicas y organizacionales y propuso etapas de adopción escalonadas para las PYMES.

Eldred et al. (2023), en su estudio titulado *Leveraging AI for Inventory Management and Accurate Forecast-An Industrial Field Study*, utilizaron datos históricos de la industria petrolera y aplicaron IA para optimizar la planificación de inventarios. Su experiencia con 17

productos clave ratifica la importancia de disponer de series temporales de alta calidad para realizar modelos de análisis.

Según Gijsbrechts et al. (2022), en *Can Deep Reinforcement Learning Improve Inventory Management? Performance on Lost Sales, Dual-Sourcing, and Multi-Echelon Problems*, se estudió en un entorno controlado cómo el aprendizaje profundo por refuerzo (DRL, algoritmo A3C) puede resolver de forma eficiente tres problemas clásicos de inventario: “lost sales”, abastecimiento dual y modelos multinivel.

Los resultados muestran que DRL consigue equiparar el desempeño de heurísticas avanzadas y de métodos de programación dinámica aproximada, con la ventaja de que requiere mínimas modificaciones en sus parámetros para adaptarse a diferentes escenarios, por lo que se trata de una prometedora tecnología generalista para empresas sin políticas heurísticas específicas. Esto proporciona un marco comparativo para la tesis, al mostrar que técnicas avanzadas de IA también mejoran los inventarios, respaldando la relevancia de investigar alternativas basadas en LLM.

Según Hendriksen (2023), en *Artificial intelligence for Supply Chain Management: ¿Disruptive Innovation or Innovative Disruption?*, se estudia desde una perspectiva teórica y práctica la forma en que la integración de la IA más precisamente, los LLM, puede revolucionar la gestión de la cadena de suministro. Se plantea el marco conceptual de Integración de IA (AII), que diferencia según dos ejes: el nivel de integración de la IA en la cadena y su rol en la toma de decisiones, mientras que el elemento humano (cómo se interpreta y se le da sentido a la IA) conforma una capa sociotécnica fundamental.

El artículo termina concluyendo que las distintas formas de integración generan distintos tipos de disrupciones, subrayando la necesidad de colaboración interdisciplinaria y de planteamientos que vayan más allá de lo técnico a la hora de pensar la implementación de IA.

Este aporte es importante para la tesis ya que señala que la adopción de LLM en MYPES no solo implica un cambio tecnológico, sino también organizacional y cultural, lo que debe considerarse tanto en el diseño del prototipo como en la estrategia de implementación.

Según la investigación de Hossam et al. (2024), en *Revolutionizing Retail Analytics: Advancing Inventory and Customer Insight with AI*, se analizaron más de dos millones de transacciones en el sector retail, empleando IA para la predicción de la conducta del cliente y la optimización de inventarios. Comprobaron que los modelos entrenados con *big data* pueden escalar.

Según la investigación de Hristov et al. (2022), en *Artificial Intelligence Systems for Warehouses Stocks Control*, estudiaron el control de inventarios mediante IA y reconocimiento de imágenes. La propuesta autónoma que presenta está pensada para su aplicación en entornos con limitaciones de personal especializado.

En el estudio de Ines et al. (2024), en *The Role of AI in Enhancing Decision-Making in Small and Medium Enterprises (SMEs)*, se llevó a cabo una investigación cuantitativa en Filipinas, analizando cómo la IA ha impulsado la toma de decisiones en 100 pequeñas y medianas empresas. El estudio mostró mejoras importantes en eficiencia operativa y planificación, lo que validó su aplicabilidad en contextos similares al de Arequipa.

Según Jackson et al. (2024), en *Generative Artificial Intelligence in Supply Chain and Operations Management: A Capability-Based Framework for Analysis and Implementation*, se plantea un marco teórico desde la *resource-based view* para analizar cómo la IA y la IA generativa (GAI) impactan 13 áreas decisorias clave en la cadena de suministros, como el pronóstico de demanda, gestión de inventarios, diseño de cadena y gestión de riesgos, a través de capacidades como el aprendizaje, la percepción, la predicción, la interacción, la adaptación y el razonamiento.

Este marco ayuda a los gerentes a reconocer dónde y cómo pueden utilizar IA/GAI para mejorar la toma de decisiones, optimizar procesos, priorizar inversiones y construir capacidades técnicas. El presente artículo apoya la tesis al ofrecer una guía estratégica para la aplicación de los LLM a la gestión de inventarios en las MYPES, garantizando que la solución propuesta contemple tanto aspectos operativos como capacidades institucionales y estratégicas.

Jamee et al. (2025), en su estudio titulado “*Mejorando la toma de decisiones en la cadena de suministro con modelos de lenguaje grandes: Un estudio comparativo de optimización impulsada por IA*”, realizaron una comparación entre soluciones basadas en LLM y los métodos tradicionales de IA (como *XGBoost* y *LSTM*) para tareas cruciales de la cadena de suministro, como el pronóstico de demanda, la selección de proveedores, el control de inventarios y la logística; los hallazgos revelaron que los modelos LLM demostraron mayor precisión y una mejor adaptación para procesar datos complejos y variados, lo que indica que estos sistemas podrían ser especialmente valiosos para los MYPES que desean automatizar y optimizar sus decisiones de inventario con recursos limitados, utilizando el razonamiento conversacional y la versatilidad analítica que proporcionan los LLM. Este trabajo está directamente vinculado con la tesis, ya que demuestra que los LLM superan a técnicas tradicionales en la optimización de inventarios.

Según Jiar Abdelkarim y Serghini Meryem (2025), en *Supply Chain Decision-Making: Complexity and Challenges*, se realizó un estudio cuantitativo con 30 gerentes de la cadena de suministro, identificando variables clave como la tasa de adopción de *chatbots*, la facilidad de uso, el nivel de integración y la precisión de los pronósticos. El análisis indica que, a medida que las cadenas se vuelven más complejas, los *chatbots* y asistentes de IA se perfilan como herramientas importantes para mejorar la agilidad y precisión de las decisiones operativas. Esto reafirma la necesidad de desarrollar un sistema LLM para inventarios en MYPES que se centre en la usabilidad y la precisión, con un enfoque accesible y práctico.

Kim et al. (2022), en *Framework of 2D KDE and LSTM-Based Forecasting for Cost-Effective Inventory Management in Smart Manufacturing*, propusieron un modelo de pronóstico de demanda para PYMES que combina LSTM con estimación de densidad en dos dimensiones (2D KDE) para producir predicciones puntuales y por intervalos ajustando las estimaciones al costo de errores de sobreestima o subestima del inventario, y demostraron que este enfoque reduce los costes frente a modelos basados solo en LSTM bajo datos muy variables. Este estudio es especialmente importante para la tesis porque demuestra cómo se puede mejorar la confiabilidad del pronóstico (y la relevancia del pedido) en entornos de PYMES con datos volátiles al incluir intervalos y costos, lo cual permitirá que el prototipo LLM considere no solo la cantidad recomendada, sino también la incertidumbre al estimar inventarios en Arequipa.

Según M. Liu et al. (2021), en *Inventory Management with LLM: Automated Decision-Making for Order Timing and Quantity*, se desarrolló un sistema automático de gestión de inventarios basado en Transformer LLM que, a partir de datos históricos y contexto del proveedor (lead time variable), aprende a decidir cuándo y cuánto reabastecer mediante aprendizaje por imitación (*imitating ex-post* decisiones óptimas).

Sus estudios empíricos en datos reales de una plataforma de comercio electrónico muestran que esta aproximación logra menores costos cuando se compara con métodos tradicionales y *benchmarks* de última generación, y ofrece además análisis teórico de su costo promedio diario bajo ciertas condiciones. Este trabajo apoya directamente la tesis ya que propone una arquitectura muy cercana al prototipo planteado, donde el LLM produce recomendaciones de pedido basadas en datos históricos y contexto operacional, lo cual mejora la precisión de decisiones de inventario en MYPES.

Liu & Vakharia (2024), en *Optimizing Supply Chain Management Through BO-CNN-LSTM for Demand Forecasting and Inventory Management*, plantean un modelo híbrido BO-

CNN-LSTM que incorpora optimización bayesiana para el ajuste de hiper parámetros, redes convolucionales (CNN) para extraer características espaciotemporales de la demanda, y LSTM para abordar dependencias temporales.

Este enfoque ha demostrado ser superior en eficiencia operativa y control de costos, ya que permite mejorar la precisión de los pronósticos y optimizar los niveles de inventario con relación a métodos tradicionales. El presente estudio resulta de gran importancia para la tesis ya que muestra cómo los modelos más sofisticados pueden combinarse con técnicas de optimización, a fin de mejorar la recomendación de pedidos y la gestión de inventario en las MYPES, apoyando la propuesta de prototipo LLM.

Y. Liu et al. (2025), en su estudio titulado *A Machine learning Approach to Inventory Stockout Prediction*, uso un *dataset* de retail con más de 1.6 millones de *SKUs* para el desarrollo de un modelo basado en algoritmos clásicos de *machine learning* que mejore la predicción de quiebres de *stock*.

En el estudio se aplica el problema del desequilibrio de datos mediante técnicas como SMOTE con Tomek Links, y se identifica que los factores más influyentes para predecir *stockouts* son: niveles actuales de inventario, pronósticos de demanda a corto plazo (tres meses) y ventas recientes. También se infiere que los pronósticos a corto plazo tienen mayor poder predictivo que los de largo plazo (seis o nueve meses), resaltando el valor de los indicadores más cercanos en el tiempo. La relevancia de este estudio para la tesis radica en que presenta un modelo factible para MYPES con gran cantidad de *SKUs*, capaz de predecir faltantes de inventario empleando datos recientes y en lapsos cortos, acorde con la estructura del prototipo LLM propuesto, que incluye predicción operativa basada en datos actuales, lo cual puede elevar la precisión de las recomendaciones de reabastecimiento en MYPES arequipeños.

Según Oviedo-Bayas et al. (2025), en su estudio *Artificial Intelligence Demand Forecasting for Improved Inventory and Fleet Management*, compararon modelos avanzados

como RNN, Transformers y *Gradient Boosting* con métodos estadísticos tradicionales (ARIMA, Suavizado Exponencial) encontrando que los modelos basados en IA redujeron hasta 50% el error de pronóstico, los costos logísticos en 31.5% y los kilómetros vacíos en 15%.

El trabajo es pertinente para la tesis, ya que muestra que el uso de modelos modernos puede dar lugar a importantes mejoras operativas, respaldando la inclusión en el prototipo de componentes que no solamente realicen recomendaciones de pedidos de inventario, sino que optimicen los gastos de operación logística.

Según la investigación de Patil et al. (2024), en *Development of MS Excel and Power BI Integrated Production Scheduling System for an MSME*, desarrollaron una herramienta de planificación de producción integrada con Power BI y MS Excel. No incluye IA, pero sirve como ejemplo de soluciones prácticas con visualización avanzada.

Según Preil & Krapp, (2022), emplearon un enfoque de búsqueda de árbol Monte Carlo para la gestión de inventarios simulada en *Artificial Intelligence-based Inventory Management: A Monte Carlo Tree Search Approach*. Su estudio, llevado a cabo en Alemania, mostró una reducción efectiva del efecto “*bullwhip*”, brindando una técnica adaptable para contextos logísticos locales.

En el trabajo de Quan & Liu (2024), en *InvAgent: A Large Language Model-based Multi-Agent System for Inventory Management in Supply Chains*, en el que se propone una arquitectura multi-agente basada en LLM que opera en modo *zero-shot*, en la que diferentes agentes coordinados gestionan tareas como pronóstico, planificación y reposición de inventarios; adicionalmente, el sistema genera recomendaciones justificadas en lenguaje natural y logra reducir costos y quiebres de *stock* cuando es comparado con políticas heurísticas y algoritmos de refuerzo. Este trabajo es muy relevante para la tesis ya que presenta un modelo funcional muy parecido al prototipo propuesto, demostrando que un LLM no solo puede servir

para generar recomendaciones, sino que también puede ser integrado de forma explicable y eficiente en la operación de inventarios de las MYPES.

Según Rolf et al. (2023), *A review on reinforcement learning algorithms and applications in supply chain management*, se realizó una revisión semi sistemática de literatura que explora los distintos algoritmos de aprendizaje por refuerzo (RL) aplicados a la gestión de la cadena de suministro, destacando que los problemas de inventario son uno de los dominios más comunes de aplicación.

El estudio explora los beneficios de aplicar RL para optimizar decisiones de reposición, gestión de inventarios y niveles de servicio ante la incertidumbre de la demanda y la oferta. Este artículo es de utilidad a la tesis al respaldar la viabilidad de incorporar técnicas avanzadas como RL al prototipo LLM propuesto, especialmente para escenarios donde se busca mejorar la política de pedidos automática ante fluctuaciones reales y reducir quiebres de inventario.

De acuerdo con Rolón Ramírez (2024), *Transformación Tecnológica en el Modelo de Gestión de Inventarios en las Mipymes, Revisión Bibliográfica*, estudio cualitativo descriptivo que examina bibliografía especializada sobre la innovación tecnológica aplicada a la gestión de inventarios de PYMES, se determina que la adopción de recursos digitales ha modificado de manera significativa la manera en que estas empresas controlan, registran y vigilan sus existencias.

Se identifican beneficios como mayor precisión, seguimiento más frecuente, decisiones más basadas en datos y reducción de errores, pero también desafíos importantes como la inversión inicial y la capacitación del personal. El trabajo apoya la tesis al demostrar que las MYPES de contextos comparables necesitan tecnologías asequibles (tales como prototipos LLM) que se centren en usabilidad, precios razonables y asistencia al usuario, con el fin de que logren una transformación exitosa en la gestión de inventarios.

En el trabajo de Saraogi et al. (2019), *An Un-Supervised Approach for Backorder Prediction Using Deep Autoencoder*, se desarrolló un modelo de predicción de *backorders* con base en *autoencoders* no supervisados. Aún hoy, después de tantos años de su publicación, la metodología sigue vigente debido a que permite anticipar rupturas de *stock*.

Según la investigación de Sathyabama et al. (2024), en *AI-Driven Expiry Prediction and Dynamic Pricing System for Retail Inventory Management Utilizing ARIMA and LSTM Models*, se propuso un sistema de predicción de caducidad y precios dinámicos mediante el uso de los modelos ARIMA y LSTM. Este estudio, desarrollado en India, proporciona una útil perspectiva temporal para productos de alto giro y perecederos.

Según Srivastava et al. (2024), en *Exploring the Potential of Large Language Models in Supply Chain Management: A Study Using Big Data*, se identificaron temas emergentes sobre el uso de *LLMs* en la cadena de suministro a través de la triangulación de datos, analizando 33 artículos académicos y más de 3 400 documentos de redes sociales y reportes industriales, tales como, optimizaciones, gestión de riesgo y seguridad, gestión del conocimiento, inteligencia contractual automatizada.

Este estudio revela qué áreas ya están avanzadas y dónde hay brechas (p. ej. implementación real, contratos automatizados, seguridad) y mapea el estado del arte del uso de *LLM*.

Apoya la tesis ofreciendo un estado de la cuestión sobre temas de *LLM* aplicables a inventarios, mostrando que, si bien existen muchas potencialidades, hay espacios no cubiertos aún que el prototipo puede abordar, como la inteligencia contractual o gestión de conocimiento local.

Según Porfirio et al. (2024), en *Artificial Intelligence and its Impact on Inventory Management in the Supply Chain*, se estudió cómo el uso del aprendizaje automático, la optimización avanzada y los algoritmos de agrupamiento impactan positivamente en la gestión

de inventarios en la industria de autopartes de Guanajuato (130 empresas), reportando mejoras notables en la utilización del almacén pasando de un 68 % de saturación a aproximadamente 93 %, lo que indica una mejora de cerca del 25 % en eficiencia espacial y una reducción importante de la necesidad de almacenaje externo.

El estudio es relevante para la tesis ya que muestra que en contextos industriales latinoamericanos es posible obtener ganancias operativas significativas con IA, respaldando así la aplicabilidad local de un prototipo LLM para mejorar el uso del espacio, reducir costos de inventario y optimizar procesos en las MYPES de Arequipa.

Tiwari et al. (2025), en *Leveraging LSTM for precision inventory management by future demand forecasting*, plantean un modelo LSTM combinado con minería de *high-utility itemsets* que identifique los artículos más rentables y patrones de consumo frecuentes, con una precisión del 98 % para predecir qué productos serán demandados en el futuro, permitiendo agrupar a los consumidores de productos similares y priorizar inventario para los ítems con mayor utilidad.

Este estudio refuerza tu tesis al demostrar que, incluso en contextos con gran cantidad de *SKUs* como los que presentan muchas MYPES, es posible obtener predicciones muy precisas empleando modelos LSTM; esto puede servir de complemento a tu prototipo LLM para lograr recomendaciones de inventario más enfocadas y basadas en información sólida.

Según Fosso Wamba et al. (2023), en *Are both generative AI and ChatGPT game changers for 21st-Century operations and supply chain excellence?*, realizó una encuesta en el Reino Unido y EE. UU. a 315 profesionales de operaciones y cadena de suministro, concluyendo que la integración de IA generativa y ChatGPT permite mejoras significativas en la eficiencia, agilidad y desempeño global de la cadena de suministro.

No obstante, constataron que menos del 10 % de las compañías han incorporado estas tecnologías, identificando como obstáculos fundamentales las preocupaciones sobre seguridad, los riesgos operativos y el aspecto ético.

Este estudio es relevante para la tesis porque resalta que el uso de LLM en la gestión de inventarios de MYPES debe ir acompañado de pautas éticas y de seguridad.

La revisión de estos estudios muestra un consenso internacional en cuanto al valor de la inteligencia artificial y la visualización de datos en el mejoramiento de la gestión de inventarios y la toma de decisiones.

Estas investigaciones reafirman la relevancia del proyecto en desarrollo, respaldando tanto el marco teórico como el enfoque metodológico propuestos en la tesis, evidenciando que la integración de modelos LLM se presenta como una solución innovadora, contextualizada y factible para las MYPES comerciales de Arequipa.

Con el fin de exponer de forma ordenada los aspectos más importantes de los estudios revisados, así como sus resultados, se muestra la Tabla 6, en la que se detallan los enfoques, contribuciones y, en su caso, los resultados cuantitativos reportados en las investigaciones revisadas.

Tabla 6
Principales aportes y resultados del estado del arte

Autor y año	Aporte principal	Resultados / conclusiones
Aktepe et al. (2021)	Predicción de demanda con IA	Permite anticipar la demanda y mejorar la planificación operativa
Akter et al. (2025)	IA en supply chain	Identifica desafíos técnicos y estratégicos en su adopción
Albayrak Ünal et al. (2023)	Revisión de IA en inventarios	Análisis de 59 estudios que evidencian optimización logística y reducción de costos
Alfaro Pareja et al. (2023)	IA + Power BI	Mejora el control y la toma de decisiones en empresa real

Tabla 6 (continuación)

Autor y año	Aporte principal	Resultados / conclusiones
Ayinaddis (2025)	Adopción de IA	Identifica 10 dimensiones clave y concluye que las MYPES requieren soluciones adaptadas
Barragán Ramírez et al. (2025)	BI en inventarios	Baja adopción en 9 empresas, pero reconocimiento de beneficios operativos
Carayannis et al. (2025)	IA estratégica	Mejora la resiliencia y competitividad empresarial
Condori et al. (2024)	IA con Python	Automatiza procesos y reduce errores en inventarios
Cortez- Vásquez & García Conde (2024)	IA en control	Mejora trazabilidad y detección de anomalías
Daios et al. (2025)	IA en supply chain	Mejora eficiencia operativa y toma de decisiones
Dhaliwal et al. (2023)	IA en inventarios	Identifica barreras y propone adopción progresiva en PYMES
Eldred et al. (2023)	IA aplicada	Mejora la precisión de pronósticos con datos reales
Gijsbrechts et al. (2022)	Deep RL	Alto rendimiento y adaptabilidad frente a métodos tradicionales

Tabla 6 (continuación)

Autor y año	Aporte principal	Resultados / conclusiones
Hendriksen (2023)	IA + LLM	Destaca impacto organizacional y sociotécnico
Hossam et al. (2024)	IA en retail	Análisis de +2 millones de datos, alta escalabilidad
Hristov et al. (2022)	IA en almacenes	Soluciones accesibles para entornos con pocos recursos
Ines et al. (2024)	IA en PYMES	Mejora significativa en eficiencia y toma de decisiones (100 empresas)
Jackson et al. (2024)	IA generativa	Impacta 13 áreas clave en supply chain
Jamee et al. (2025)	LLM vs tradicional	Mayor precisión y adaptabilidad en decisiones
Jiar Abdelkarim y Serghini Meryem (2025)	Chatbots IA	Mejora rapidez y precisión (30 gerentes)
Kim et al. (2022)	LSTM + KDE	Reduce costos mediante mejor estimación de demanda
M. Liu et al. (2021)	LLM en inventarios	Reduce costos y mejora decisiones de reabastecimiento
Y. Liu et al. (2025)	ML en <i>stockouts</i>	Análisis de 1.6M SKUs, identifica variables clave

Tabla 6 (continuación)

Autor y año	Aporte principal	Resultados / conclusiones
Oviedo-Bayas et al. (2025)	IA vs tradicional	Reducción del error en 50 %, reducción de costos en 31.5 % y disminución de kilómetros recorridos en 15 %.
Patil et al. (2024)	Power BI	Integración de Power BI que mejora la visualización y apoya la planificación operativa en PYMES.
Preil & Krapp, (2022)	Monte Carlo	Método Monte Carlo que reduce el efecto bullwhip y mejora la precisión de pedidos.
Quan & Liu (2024)	LLM multi agente	Reduce costos y quiebres de <i>stock</i>
Rolón Ramírez (2024)	Digitalización MYPES	La digitalización mejora el control del inventario, pero exige inversión y capacitación.
Saraogi et al. (2019)	Deep Learning	Predicción eficaz de quiebres de <i>stock</i>
Sathyabama et al. (2024)	ARIMA + LSTM	ARIMA y LSTM optimizan inventarios mediante predicción y precios dinámicos.
Srivastava et al. (2024)	LLM en supply chain	Identifica avances y brechas (33 artículos + 3400 <i>docs</i>)

Tabla 6 (continuación)

Autor y año	Aporte principal	Resultados / conclusiones
Tamayo et al. (2024)	IA en inventarios	Mejora de 68% a 93% (~25%)
Tiwari et al. (2025)	LSTM	Precisión del 98% en predicción
Wamba et al. (2023)	IA generativa	Mejora eficiencia; adopción <10% (315 encuestados)

Nota. Elaboración Propia

2.3. Bases Teóricas de la Investigación

Es fundamental para el correcto desarrollo y comprensión de esta investigación establecer los conceptos teóricos en que se basa el estudio. A continuación, se exponen las bases conceptuales relacionadas con la inteligencia artificial aplicada a la gestión de inventarios y la toma de decisiones empresariales, particularmente, en el contexto de las micro y pequeñas empresas (MYPES).

2.3.1. Inteligencia Artificial en la Gestión de Inventarios

La inteligencia artificial (IA) es un área de la informática que se enfoca en diseñar sistemas capaces de realizar actividades que, históricamente, han necesitado inteligencia humana, tales como aprender, tomar decisiones y reconocer patrones. La IA en la gestión de inventarios, automatiza y optimiza procesos analizando grandes volúmenes de datos históricos y en tiempo real, facilitando el acceso, procesamiento e interpretación de la información para respaldar una toma de decisiones más eficiente sobre la disponibilidad y control de productos.

El uso de modelos de lenguaje avanzado (Large Language Models - LLM) y otras técnicas de IA, como redes neuronales y algoritmos de aprendizaje automático, ha revolucionado la forma en que las empresas pueden anticipar comportamientos de consumo,

reducir errores humanos y mejorar la eficiencia operativa (Albayrak Ünal et al., 2023; Dhaliwal et al., 2023). Estas tecnologías aprovechan datos históricos para apoyar el análisis de información y facilitar la toma de decisiones en torno al control de inventarios, contribuyendo a disminuir los costos asociados al *sobrestock* o desabastecimiento.

En la Figura 1 del documento se puede observar un diagrama que muestra cómo será el funcionamiento del *Chatbot* como propuesta usando LLM e IA para poder tener un mejor manejo del inventario y poder realizar una consultas relacionadas con productos, *stock*, ventas y movimientos de inventario.

2.3.2. Modelos de Lenguaje de Gran Escala (LLM) y Procesamiento de Lenguaje Natural (PLN)

Los modelos de lenguaje de gran escala (LLM) son uno de los avances más importantes de la inteligencia artificial moderna. Estos sistemas son capaces de entender y producir lenguaje natural a partir de grandes volúmenes de texto, mediante redes neuronales profundas basadas en la arquitectura Transformer.

A diferencia de los modelos estadísticos tradicionales, los LLM pueden entender el contexto semántico del lenguaje y generar respuestas coherentes, lo que los convierte en herramientas útiles para aplicaciones empresariales que requieren interacción natural con los datos, como la gestión de inventarios y la toma de decisiones operativas (OpenAI, 2023; Brown et al., 2020).

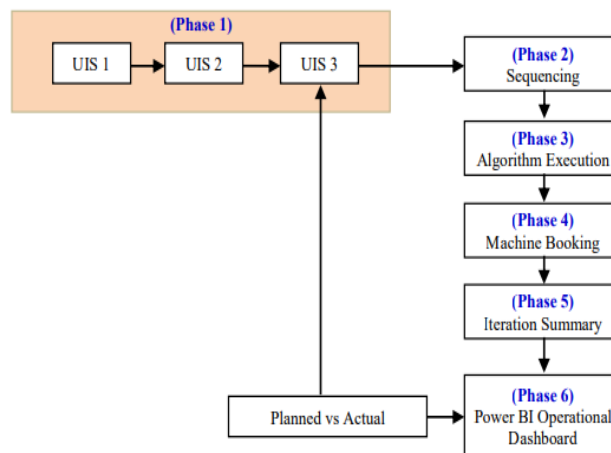
Modelos como GPT (*Generative Pre-trained Transformer*) utilizan técnicas de aprendizaje profundo y procesamiento del lenguaje natural (PLN) para transformar consultas en lenguaje humano en instrucciones estructuradas, lo que facilita su uso en sistemas conversacionales y entornos corporativos.

2.3.3. Visualización de Datos y Herramientas de Business Intelligence:

La visualización de datos y las herramientas de inteligencia de negocios son antecedentes importantes para entender cómo las empresas pueden interpretar la información de inventarios. No obstante, en el presente trabajo el acceso a la información se plantea principalmente a través de una interfaz conversacional basada en LLM, por lo que estas herramientas se consideran como referencia complementaria y no como parte integrante del sistema propuesto. En el entorno de las MYPES, el uso de Power BI se convierte en un recurso accesible para transformar datos complejos en insights comprensibles, disminuyendo la dependencia de expertos en análisis y fomentando una cultura organizacional orientada a datos (Alfaro Pareja et al., 2023; Patil et al., 2024).

En la Figura 1 se muestra el marco del sistema integrado con Power BI propuesto por Patil et al. (2024), donde se puede apreciar el modo en que esta herramienta puede servir de apoyo al análisis y a la transformación de datos complejos. También, en la Figura 2 se muestra el diagrama de flujo correspondiente a la integración de Power BI.

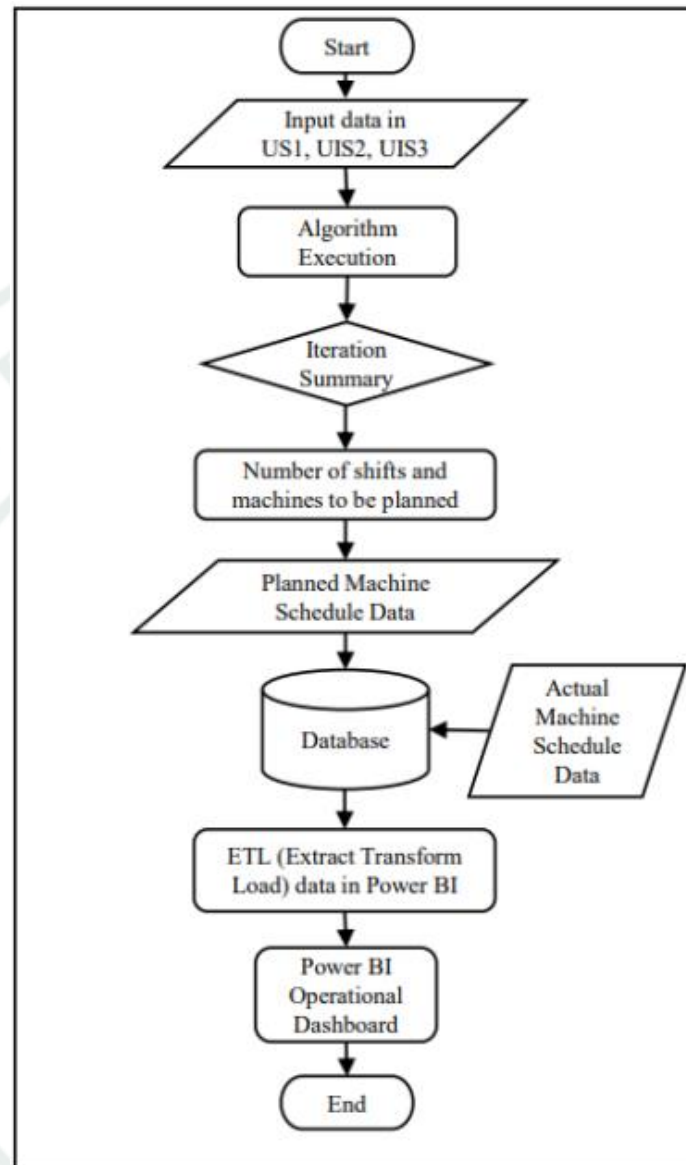
Figura 1
Marco del sistema LLM Integrado con Power BI



Nota. Adaptado de Patil, P. S., Patil, S. S., Patil, S. M., & Dhanvijay, M. R. (2024). *Development of MS Excel and Power BI Integrated Production Scheduling System for an MSME*, p. 7. *Engineering Access*, 10(2), 124–142. <https://doi.org/10.14456/mijet.2024.15>

Figura 2

Diagrama de flujo de la Integración de Power BI



Nota. Adaptado de Patil, P. S., Patil, S. S., Patil, S. M., & Dhanvijay, M. R. (2024). *Development of MS Excel and Power BI Integrated Production Scheduling System for an MSME*, p. 12. *Engineering Access*, 10(2), 124–142. <https://doi.org/10.14456/mijet.2024.15>

2.3.4. Gestión de Inventarios en Micro y Pequeñas Empresas

Las MYPES constituyen un sector vital para la economía local, pero suelen enfrentar limitaciones técnicas y operativas en la gestión de sus inventarios. Estas empresas a menudo dependen de métodos tradicionales y subjetivos para tomar decisiones, lo que conlleva

ineficiencias y riesgos de quiebre de *stock* o acumulación innecesaria de productos (Condori et al., 2024; Ines et al., 2024).

El uso de tecnologías basadas en IA permite superar estas limitaciones, con herramientas adecuadas a la capacidad técnica y económica de las MYPES. Estas facilitan el acceso y análisis de la información de inventarios, mejorando la planificación de compras, disminuyendo las pérdidas por exceso de mercadería y evitando problemas de atención a la demanda.

De igual manera las herramientas tecnológicas accesibles ayudan a la toma de decisiones sin necesidad de conocimientos avanzados. De tal manera que, las soluciones basadas en IA no suplantán el criterio del usuario, sino que lo complementan con información ordenada, ágil y útil para mejorar la gestión del inventario, optimizar recursos y fortalecer la competitividad.



CAPÍTULO III

3. MARCO METODOLOGICO

3.1. Alcances y Limitaciones

El presente estudio tiene como alcance el diseño y validación de un sistema de apoyo a la toma de decisiones para la gestión de inventarios en micro y pequeñas empresas (MYPES) del sector comercial de Arequipa, basado en un *chatbot* como interfaz de interacción. El estudio comprende desde la recopilación y análisis de datos hasta la implementación del sistema propuesto, el cual será evaluado mediante la aplicación de instrumentos antes y después de su uso, con el fin de analizar su impacto en el proceso de toma de decisiones.

Queda fuera del alcance del estudio el desarrollo de una solución completamente automatizada para su implementación inmediata a gran escala, así como la integración con sistemas ERP complejos u otras plataformas de gestión empresarial que requieran licencias propietarias o infraestructura adicional de alto costo.

Viabilidad: La investigación es viable, ya que se utilizarán herramientas accesibles y de bajo costo como Python (con bibliotecas *open source* para *machine learning*). Las fuentes de datos serán de carácter secundario, complementadas con datos primarios proporcionados por MYPES locales que acepten participar voluntariamente en el estudio. Además, el equipo de investigación cuenta con el conocimiento técnico necesario para el desarrollo y análisis del sistema propuesto.

Lugar: La investigación se desarrollará en la ciudad de Arequipa, específicamente en el sector comercial, con un enfoque en MYPES ubicadas en los distritos de Socabaya, Paucarpata y Jacobo Hunter, que presentan alta actividad económica y diversidad de negocios.

Tiempo: El estudio se ejecutará durante el año 2025, distribuyéndose en etapas que incluyen el levantamiento de información, el desarrollo del prototipo de sistema, las pruebas del *chatbot*, y la validación con empresas participantes. El tiempo previsto es de seis meses, con un margen de ajuste para imprevistos operativos.

Financiación: La investigación será autofinanciada. No se requiere una inversión económica significativa, ya que se trabajará con software de libre acceso y no se contempla la implementación física del sistema en las empresas, sino su validación a nivel prototipo.

3.2. Tipo y Nivel de la Investigación

La presente investigación es de tipo aplicada y tecnológica, dado que tiene como propósito principal la implementación práctica de herramientas basadas en inteligencia artificial para optimizar la toma de decisiones en la gestión de inventarios de las micro y pequeñas empresas (MYPES) del sector comercial de Arequipa, la investigación busca resolver una problemática real identificada en las MYPES: la ineficiencia en la administración del inventario debido al uso limitado de tecnologías analíticas. En ese sentido, se propone el diseño y validación de un sistema conversacional que emplea modelos de lenguaje de gran escala (LLM) como herramienta de apoyo para aportar mejoras tangibles en la planificación y toma de decisiones.

Asimismo, esta investigación también es de tipo tecnológica, ya que contempla el desarrollo de un sistema funcional orientado a facilitar el acceso y análisis de la información de inventarios mediante una interfaz conversacional en lenguaje natural. Este tipo de solución representa un producto digital orientado a intervenir directamente en procesos empresariales, aportando eficiencia y sostenibilidad a las operaciones.

En cuanto al nivel de investigación, esta tesis es de nivel descriptivo-explicativo:

- Descriptivo, porque permite caracterizar el estado actual de la gestión de inventarios en las MYPES de Arequipa, identificando prácticas comunes, deficiencias, herramientas utilizadas y necesidades no cubiertas.
- Explicativo, porque se analiza el efecto de aplicar un sistema conversacional basado en modelos de lenguaje de gran escala (LLM) en la mejora de la toma de decisiones,

considerando su impacto en variables como planificación, abastecimiento, rotación de inventario y satisfacción del cliente.

El enfoque es de tipo cuantitativo porque busca medir el impacto de la aplicación de modelos de inteligencia artificial (LLM) en la gestión de inventarios en las MYPES comerciales de Arequipa.

A través de este enfoque, se pretende recolectar datos numéricos y objetivos que permitan analizar el efecto de la implementación de estas tecnologías en aspectos clave como la eficiencia operativa, la toma de decisiones, la reducción de *sobrestock* y desabastecimiento, y el nivel de satisfacción de los usuarios.

Además, el enfoque cuantitativo permite validar las hipótesis mediante el análisis estadístico de los datos obtenidos a través de encuestas estructuradas y registros del sistema, los cuales permiten medir la percepción y la efectividad del *chatbot* en el proceso de toma de decisiones.

Este tipo de análisis es fundamental para comprobar la efectividad del sistema propuesto, ya que brinda resultados medibles, comparables y replicables que se pueden aplicar a otras MYPES en contextos similares.

Brinda una base sólida para la evaluación de resultados, permitiendo la comparación del efecto que tuvo la implementación del sistema en la gestión de inventarios, a partir de las mediciones realizadas antes y después de su uso.

3.3. Universo, Población y Muestra

Universo o Población

El universo de esta investigación lo constituyen todas las micro y pequeñas empresas (MYPES) ubicadas en la ciudad de Arequipa, Perú. Arequipa tiene 133,846 empresas activas, según el Instituto Nacional de Estadística e Informática (INEI, 2022), de las cuales el 95.8% son microempresas, lo que representa aproximadamente 128,000 unidades. El periodo de

estudio se corresponde con el año 2025, tomando como referencia información actualizada y disponible hasta el primer semestre de ese año.

La población de esta investigación la conforman las MYPES comerciales que manejan inventarios de productos físicos en Arequipa. El INEI señala que aproximadamente el 45.3% de las empresas en Arequipa pertenecen al sector comercio, lo que equivale a una población estimada de 57,984 empresas comerciales en la región. Estas empresas tienen en común el uso limitado de herramientas tecnológicas, procesos manuales o empíricos para tomar decisiones y el acceso restringido a soluciones avanzadas como inteligencia artificial o plataformas de Business Intelligence.

Se consideró como una población homogénea, ya que todas las unidades presentan condiciones similares en cuanto a su tamaño, nivel de digitalización, tipo de operaciones y recursos tecnológicos disponibles.

Muestra

Dado que no se cuenta con un censo completo y actualizado de todas las MYPES comerciales activas en Arequipa, se recurrió a un muestreo no probabilístico por juicio, seleccionando empresas que cumplan con los siguientes criterios:

- Ser una MYPE formalmente constituida en Arequipa.
- Pertenecer al sector comercio (retail, distribución, venta de productos).
- Gestionar inventario de productos físicos (no aplica para servicios).
- No contar con herramientas avanzadas de predicción o visualización implementadas previamente.

La muestra estará constituida por 40 empresas, seleccionadas intencionalmente debido a su disponibilidad para participar en entrevistas, presentación de prototipo y proceso de validación de la propuesta tecnológica desarrollada. Con esta muestra se podrá aplicar y evaluar el funcionamiento del chatbot basado en modelos de lenguaje a gran escala (LLM), analizando

los resultados de manera cuantitativa y cualitativa, manteniendo la representatividad necesaria para cumplir los objetivos de la investigación.

También se han realizado conversaciones previas con las 40 MYPES consideradas en la muestra, con el objetivo de coordinar la presentación del prototipo y su participación en el proceso de validación.

La investigación está orientada a la demostración funcional del sistema y a la aplicación de instrumentos de evaluación antes y después de su uso, con los datos registrados en el prototipo.

3.4. Métodos, Técnicas e Instrumentos de Recolección de Datos

En la presente investigación se utilizarán diferentes técnicas y procedimientos para recolectar los datos pertinentes que permitan alcanzar los objetivos propuestos. Estas técnicas están orientadas a obtener información de las MYPES comerciales de Arequipa sobre su gestión de inventarios y sobre la implementación de herramientas basadas en inteligencia artificial orientadas al apoyo en la toma de decisiones.

Método Cuantitativo

El método que se usará será cuantitativo, dado que se pretende medir el impacto de la aplicación del sistema propuesto sobre la gestión de inventarios en las MYPES comerciales. Este enfoque recopilará datos numéricos y estructurados que permitan analizar la efectividad del chatbot basado en modelos de lenguaje de gran escala (LLM) en el proceso de toma de decisiones.

Este enfoque facilitará la recolección de datos estructurados para un análisis estadístico más ágil de los resultados obtenidos en la implementación del sistema propuesto.

Técnicas de Recolección de Datos

Se emplearán diversas técnicas para recolectar los datos, las cuales se detallan a continuación:

1. Técnica Documental

Esta técnica será empleada para la recolección de datos secundarios provenientes de fuentes bibliográficas y electrónicas, tales como libros, artículos académicos, tesis, revistas especializadas y páginas web pertinentes para el estudio. Esta técnica permitirá tener una base teórica robusta para contextualizar el problema de investigación y entender las soluciones ya propuestas en la literatura existente.

- **Instrumento:** Fichas electrónicas y bases de datos (BBDD).

2. Observación

Se utilizará la observación directa para conocer los procesos actuales de gestión de inventarios de las MYPES comerciales seleccionadas. Esta técnica permitirá al investigador identificar cómo las empresas manejan sus inventarios sin necesidad de herramientas avanzadas de predicción, y cómo podrían mejorar estas prácticas implementando un sistema basado en IA.

- **Instrumento:** Guía de observación y lista de chequeo.

3. Encuesta

Se aplicará una encuesta a los empleados y gerentes de las MYPES seleccionadas para obtener datos cuantitativos sobre su experiencia en la gestión de inventarios y el impacto en la toma de decisiones. Las preguntas estarán estructuradas utilizando una escala de Likert para medir la percepción y actitud de los encuestados.

La encuesta estará dirigida a los responsables de la gestión de inventarios en las MYPES seleccionadas, tales como gerentes, encargados de almacén o vendedores. El cuestionario estará compuesto por ítems estructurados en función de las dimensiones de la variable de estudio, utilizando una escala de Likert de cinco niveles. Asimismo, se considerará la validez de contenido mediante la revisión de expertos y la validez de constructo a través de la coherencia entre dimensiones e indicadores.

La confiabilidad del instrumento será evaluada mediante el coeficiente Alfa de Cronbach. Finalmente, la relación entre ítems, indicadores y dimensiones se detalla en la matriz correspondiente, la cual se presenta en los anexos.

- **Instrumento:** Cuestionario estructurado con escala de Likert.

Instrumentos de Recolección de Datos

A continuación, se detallan los instrumentos utilizados para la recolección de los datos:

1. Fichas Electrónicas

Las fichas electrónicas se emplearán para organizar y almacenar la información obtenida de fuentes secundarias. Se estructurarán para permitir la rápida clasificación de las citas bibliográficas y los resúmenes de los estudios revisados, facilitando el análisis de la literatura relevante.

2. Guía de Observación

La guía de observación estará compuesta por un conjunto de indicadores a observar durante las visitas a las MYPES. La observación se centrará en identificar prácticas y comportamientos relacionados con la gestión de inventarios y el uso de tecnología.

3. Cuestionario Estructurado con Escala de Likert

El cuestionario estructurado con escala de Likert se utilizará para medir la percepción de los empleados y gerentes sobre la efectividad de la gestión de inventarios y la viabilidad de la adopción de nuevas tecnologías como IA.

Las respuestas se clasificarán en una escala de 1 a 5, desde "totalmente en desacuerdo" hasta "totalmente de acuerdo", para evaluar las actitudes y opiniones de los participantes, las cuales se encuentran validadas en el Anexo A y Anexo B.

A continuación, en la Tabla 7 se presenta una síntesis general de las técnicas de recolección de datos utilizadas en la investigación, junto con sus definiciones e instrumentos asociados y su población Objetivo.

Tabla 7
Técnicas e Instrumentos de Recolección de Datos

Técnica	Definición	Instrumento	Población objetivo
Documental	Esta técnica se utiliza para recopilar y registrar datos provenientes de fuentes bibliográficas escritas y electrónicas (libros, artículos, tesis, revistas, etc.). (Guerrero Dávila, 2015).	Fichas electrónicas y bases de datos (BBDD)	Fuentes bibliográficas y documentales (libros, artículos, tesis, revistas y páginas web especializadas)
Observación	Consiste en la capacidad del investigador de observar de manera sistemática los fenómenos o situaciones que ocurren en el contexto de estudio, con un enfoque estructurado. (Castellanos, 2017).	Guía de observación, Lista de chequeo	Procesos de gestión de inventarios en las MYPES seleccionadas
Encuesta	Recolección de datos mediante cuestionarios o encuestas para investigar aspectos como opiniones, actitudes o percepciones relacionadas con el tema de estudio. (Universidad de la Empresa, 2019).	Cuestionario estructurado y Escala de Likert	Empleados y gerentes de las MYPES seleccionadas

Nota. Elaboración Propia

3.5. Plan de Análisis Estadístico de los Datos

El plan de análisis estadístico constituye un aspecto fundamental de esta investigación, ya que permite organizar y procesar los datos de manera que se puedan obtener resultados claros y útiles para responder las preguntas de investigación planteadas.

Este análisis se estructurará en varias fases, orientadas a interpretar los datos de manera objetiva, a partir de los instrumentos de recolección aplicados en las MYPES comerciales de Arequipa.

Proceso de Análisis de los Datos

1. Análisis Descriptivo:

En primer lugar, se realizará un análisis descriptivo para organizar y resumir los datos obtenidos. Se calcularán medias, medianas, modas, desviaciones estándar y frecuencias de las variables cuantitativas, lo que permitirá conocer la distribución de las características de las MYPES y las respuestas de los encuestados.

2. Clasificación y Agrupación de Datos:

Los datos obtenidos de las encuestas se clasificarán según las variables definidas en la investigación (como la eficiencia operativa, la toma de decisiones, y la adopción de herramientas tecnológicas).

Además, se agruparán por categorías relevantes, tales como tipo de empresa, sector, o nivel de adopción tecnológica.

3. Análisis Comparativo:

Se realizará un análisis comparativo de los resultados obtenidos antes y después de la aplicación del sistema propuesto, con el fin de identificar cambios en la toma de decisiones y en los indicadores vinculados a la gestión de inventarios.

Este análisis permitirá evaluar las diferencias observadas entre el *Pre-Test* y el *Post-Test* en función de los objetivos de la investigación.

4. Pruebas de Hipótesis:

Se realizarán pruebas de hipótesis para verificar la validez de la hipótesis planteada. Estas pruebas permitirán determinar si la implementación del *chatbot* basado en modelos de

lenguaje de gran escala (LLM) tiene un impacto significativo en la toma de decisiones de inventarios en las MYPES comerciales.

Se utilizarán pruebas de significancia estadística, como la prueba *t* de Student para evaluar las diferencias entre grupos y determinar la relevancia estadística de los resultados.

Herramientas y Procedimiento de Análisis

El análisis de los datos será realizado utilizando el lenguaje de programación Python, mediante librerías especializadas para el procesamiento de datos cuantitativos, análisis estadístico y generación de visualizaciones.

Se aplicarán técnicas de estadística descriptiva, tales como tablas de frecuencia, medidas de tendencia central y dispersión, además del cálculo del coeficiente Alfa de Cronbach para evaluar la confiabilidad del instrumento.

Asimismo, se elaborarán gráficos estadísticos, como diagramas de barras y gráficos comparativos, con la finalidad de representar los resultados y facilitar su interpretación.

Finalmente, se realizará el análisis comparativo entre los resultados del *Pre-Test* y *Post-Test*, a fin de evaluar la variación producida después de la implementación del *chatbot*.

Tratamiento de Datos Cualitativos

La investigación se centró en el análisis cuantitativo de los datos obtenidos mediante cuestionarios estructurados. La observación fue utilizada como apoyo complementario para contextualizar las prácticas de gestión de inventarios de las MYPES participantes.

Criterios de Validez y Confiabilidad

Se realizará un análisis riguroso y se garantizará que los instrumentos empleados sean válidos y fiables para el tipo de datos que se recojan.

La verificación de la validez de los instrumentos se realizará mediante un proceso de validación por parte de expertos en la materia, mientras que la confiabilidad se garantizará mediante el cálculo del coeficiente Alfa de Cronbach para el caso del cuestionario aplicado.

Resultados y Conclusiones

Los datos obtenidos servirán para determinar el grado de impacto que tenga el sistema propuesto en las MYPES comerciales de Arequipa, para así comprobar la efectividad que este tiene en mejorar la gestión de inventarios y la toma de decisiones.

Los resultados obtenidos permitirán emitir recomendaciones prácticas para la implementación de sistemas conversacionales basados en modelos de lenguaje a gran escala (LLM) en el contexto de las MYPES.

3.6. Consideraciones Éticas sobre el Uso de IA Generativa

En el transcurso de la realización de este trabajo se emplearon herramientas de inteligencia artificial generativa, en particular ChatGPT, con el objetivo de apoyar la tarea de formato, redacción inicial, revisión gramatical y estructuración preliminar del documento.

Es importante señalar que en ningún momento estas herramientas fueron empleadas para realizar el trabajo intelectual de interpretación de resultados, formulación de hipótesis, diseño metodológico y análisis de datos.

Los autores han revisado, validado y editado todo el contenido generado por la IA y asumen plena responsabilidad por la veracidad, integridad y originalidad del presente documento.

El uso de inteligencia artificial debe ser transparente y adecuadamente reconocido, conforme a las recomendaciones éticas establecidas por el Committee on Publication Ethics (COPE) y otras entidades científicas, sin atribuirle autoría, debido a que estas herramientas no pueden asumir responsabilidad intelectual ni ética sobre el contenido final (COPE, 2023; Gorraiz, 2025).

Así pues, se entiende que la IA operó como herramienta de apoyo técnico, como ocurre con el empleo de un programa de procesamiento de texto o análisis estadístico y no como una entidad colaboradora en la producción científica.

Esta postura se ajusta a las directrices de revistas académicas actuales, tales como *Nature* y *Science*, que establecen que el uso de IA debe declararse en los agradecimientos, aunque no debe otorgársele categoría de coautor.

En este sentido, se garantiza la transparencia del proceso y se respeta la integridad académica del trabajo presentado.

3.7. CRONOGRAMA

Diagrama de Gantt


A continuación, se muestra el Diagrama de Gantt (Figura 3) con el cronograma de actividades de la tesis de marzo a junio de 2026.

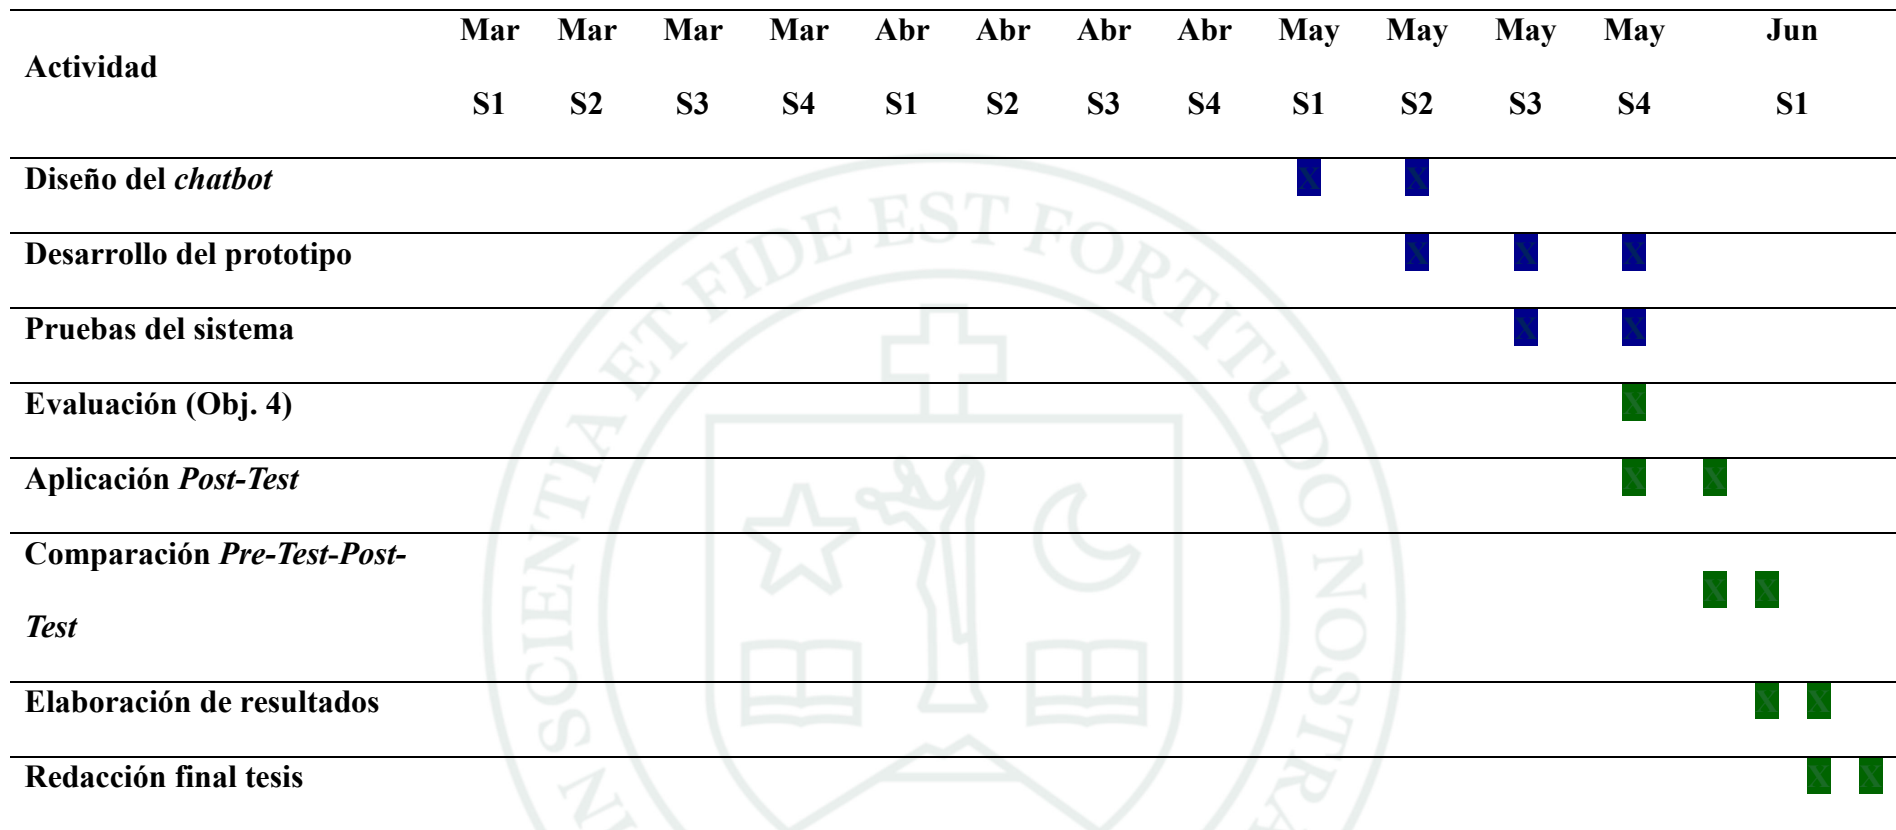
Algunas actividades como la revisión de literatura o la definición de objetivos ya están hechas. Este calendario muestra las tareas pendientes y sus fechas estimadas, lo cual asegura una investigación eficiente.

El cronograma, asimismo, permite organizar las actividades conforme a los objetivos específicos de la investigación, tomando en cuenta las etapas de diagnóstico, análisis, desarrollo del sistema y evaluación. De este modo, se establece una secuencia ordenada de trabajo, que permite facilitar el seguimiento del avance y el cumplimiento de los plazos previstos.

Figura 3

Diagrama de Gantt - Cronograma de Actividades del Plan de Tesis





Nota. Elaboración Propia



CAPÍTULO IV

4. Desarrollo de la Solución Tecnológica

4.1. Contexto del Desarrollo y Metodología SCRUM

4.1.1. Contexto del Desarrollo

El desarrollo de la presente propuesta se enmarca en el contexto de las micro y pequeñas empresas (MYPES) comerciales de Arequipa, las cuales enfrentan limitaciones tecnológicas y metodológicas para optimizar sus procesos de gestión de inventarios. A través del diagnóstico previo realizado, se identificó que la mayoría de estas empresas toman decisiones basadas en la experiencia empírica o en registros manuales, lo que genera problemas de desabastecimiento, *sobrestock* y pérdida de rentabilidad.

Ante esta realidad, se planteó el desarrollo de un sistema denominado *Querybot*, basado en Modelos de Lenguaje de Gran Escala (LLM) e integrado con una base de datos SQL Server, que permite realizar consultas sobre información de inventario mediante lenguaje natural.

Este sistema busca asistir a los responsables de inventario en la toma de decisiones informadas, reduciendo los tiempos de respuesta y mejorando la precisión operativa.

El entorno de desarrollo del proyecto estuvo constituido por un entorno de programación Python 3.10, un servidor local de base de datos SQL Server 2019, y un conjunto de datos históricos de inventario proporcionados por empresas participantes. Las pruebas y validaciones se realizaron de forma experimental, en un ambiente controlado y de carácter demostrativo, asegurando la replicabilidad del modelo en otros contextos empresariales similares.

4.1.2. Metodología SCRUM

Para el desarrollo del *Chatbot* se empleó la metodología ágil SCRUM, ampliamente utilizada en proyectos de ingeniería de software por su enfoque iterativo, flexible y centrado en el valor entregado al usuario. SCRUM facilita el trabajo en equipos reducidos, permitiendo

entregar incrementos funcionales del sistema en cortos periodos denominados *sprints*, lo que favorece la mejora continua y la adaptabilidad a cambios durante el desarrollo.

La elección de esta metodología se justifica por las siguientes razones:

- Permite entregas incrementales, adecuadas para el desarrollo de un prototipo funcional.
- Favorece la retroalimentación continua con los usuarios y asesores del proyecto.
- Se adapta a la naturaleza experimental y tecnológica de la propuesta, reduciendo riesgos y mejorando la calidad del producto final.

4.1.3. Descripción del entorno (MYPES comerciales de Arequipa).

Las micro y pequeñas empresas (MYPES) comerciales de Arequipa constituyen un componente esencial de la economía regional, ya que representan más del 95% del tejido empresarial formal.

Este grupo de empresas se caracteriza por su dinamismo, flexibilidad operativa y capacidad para generar empleo local. Sin embargo, presentan dificultades estructurales relacionadas con la gestión tecnológica, el manejo de datos y la planificación estratégica de inventarios.

El estudio se enfoca en las MYPES del sector comercial ubicadas principalmente en los distritos de Arequipa, zonas con alta concentración de tiendas dedicadas a la venta de productos de consumo masivo, repuestos, electrodomésticos y artículos tecnológicos.

Estas empresas suelen administrar sus inventarios mediante métodos empíricos, basados en la experiencia del propietario o registros en hojas de cálculo. Esta práctica conlleva errores en el cálculo de *stock*, quiebres de productos o exceso de mercancía, lo que afecta directamente la eficiencia operativa y la rentabilidad del negocio.

Ante esta problemática, la propuesta del *Chatbot* surge como una herramienta accesible y adaptable, diseñada para integrarse a las necesidades y capacidades tecnológicas de las

MYPES, mejorando su toma de decisiones a partir de información procesada con inteligencia artificial.

4.1.4. Justificación del uso de SCRUM en el desarrollo del *Chatbot*.

El uso de la metodología SCRUM en este proyecto se fundamenta en su efectividad para organizar el proceso de desarrollo de software mediante iteraciones cortas y controladas.

Dado que el *Chatbot* es un sistema de naturaleza experimental, con etapas que requieren constante validación y ajuste, SCRUM se presenta como el enfoque más adecuado para garantizar una entrega progresiva y verificable del producto.

Los principales motivos que sustentan su elección son los siguientes:

- **Iteratividad:** permite dividir el proyecto en *sprints*, donde cada ciclo entrega un módulo funcional (por ejemplo: conexión con la base de datos y módulo conversacional).
- **Flexibilidad:** facilita incorporar retroalimentación y realizar correcciones técnicas sin afectar la estructura general del proyecto.
- **Orientación al producto:** el trabajo se centra en alcanzar resultados tangibles, medibles y alineados con los objetivos de la investigación.
- **Gestión eficiente del tiempo:** posibilita planificar tareas de forma semanal y mantener un control constante sobre el progreso.

4.1.5. Roles definidos: *Product Owner, Scrum Master, Development Team*.

En esta adaptación individual como se muestra en la Tabla 8, todas las funciones del marco SCRUM fueron asumidas por el autor del trabajo Gerald Edwin Gómez Quispe, quien organizó las actividades conforme a las prácticas del modelo ágil.

Tabla 8
Roles definidos

Rol SCRUM	Descripción de funciones	Responsable
Product Owner	Define los requerimientos del sistema, prioriza las funcionalidades del <i>Chatbot</i> y se asegura de que cumpla con las necesidades de las MYPES.	Gerald Edwin Gómez Quispe
Scrum Master	Supervisa la aplicación del marco SCRUM, controla el avance de los <i>sprints</i> y gestiona los tiempos de desarrollo.	Gerald Edwin Gómez Quispe
Development Team	Diseña, programa, entrena y valida el <i>Chatbot</i> , integrando el modelo de lenguaje (LLM) y la base de datos SQL Server.	Gerald Edwin Gómez Quispe

Nota. Elaboración Propia.

4.1.6. Fases del proceso ágil: *Product Backlog, Sprint Planning, Daily, Review y Retrospective.*

El proceso de desarrollo del *Chatbot* se estructuró en torno a las fases fundamentales del marco SCRUM:

1. *Product Backlog:*

Se elaboró una lista priorizada de requerimientos, incluyendo la conexión con SQL Server, el procesamiento del lenguaje natural y la validación funcional del sistema conversacional.

2. *Sprint Planning:*

Se definieron las tareas y objetivos de cada *sprint*, con tiempos estimados, criterios de aceptación y resultados esperados.

3. *Daily Scrum:*

Se registraron los avances diarios mediante una bitácora técnica, evaluando problemas, ajustes y soluciones implementadas.

4. *Sprint Review*:

Al finalizar cada *sprint*, se revisaron los resultados obtenidos y se validó el cumplimiento de los objetivos establecidos.

5. *Sprint Retrospective*:

Se analizaron los logros y dificultades de cada ciclo, identificando oportunidades de mejora técnica y metodológica para los siguientes *sprints*.

4.1.7. Cronograma general de los *sprints* (tabla o figura).

El desarrollo del *Chatbot* se realizó en tres *sprints* consecutivos, cada uno con una duración y un entregable definidos, según se detalla a continuación en la Tabla 9:

Tabla 9
Cronograma general de los sprints

<i>Sprint</i>	Duración	Objetivo Principal	Entregable Final
<i>Sprint</i> 1	2 semanas	Configurar el entorno de desarrollo e implementar la conexión con la base de datos SQL Server.	Base de datos funcional y conexión establecida con Python.
<i>Sprint</i> 2	3 semanas	Desarrollar el <i>Chatbot</i> LLM, implementar consultas dinámicas y generar respuestas en lenguaje natural.	<i>Chatbot</i> funcional con interacción conversacional.
<i>Sprint</i> 3	3 semanas	Realizar la validación funcional del <i>chatbot</i> , aplicar pruebas integradas y evaluar el desempeño general del sistema.	Prototipo final validado con métricas de desempeño.

Nota. Elaboración Propia.

4.2. Requerimientos del Sistema

El presente apartado describe los requerimientos necesarios para el desarrollo y funcionamiento del sistema propuesto.

Estos requerimientos se dividen en funcionales y no funcionales, con el objetivo de definir de manera clara las capacidades que el sistema debe ofrecer y las condiciones bajo las cuales debe operar.

Los requerimientos funcionales detallan las acciones específicas que el *chatbot* realiza para cumplir con los objetivos del proyecto, mientras que los requerimientos no funcionales (presentados en el siguiente subapartado) establecen los criterios de rendimiento, seguridad y usabilidad necesarios para garantizar su operatividad y fiabilidad.

4.2.1. Requerimientos Funcionales

Los requerimientos funcionales definen las características operativas que el sistema debe cumplir para responder a las necesidades de las MYPES comerciales y facilitar la toma de decisiones en la gestión de inventarios.

A continuación, se describen los principales requerimientos definidos para el *chatbot*:

1. Procesamiento de consultas en lenguaje natural

El *chatbot* debe interpretar preguntas formuladas por el usuario en texto libre, relacionadas con productos, *stock*, fechas o movimientos de inventario.

2. Generación automática de consultas SQL

El modelo de lenguaje debe traducir la solicitud del usuario en una instrucción SQL válida y segura, adecuada para la estructura de la base de datos.

3. Ejecución y recuperación de resultados

El sistema debe ejecutar la consulta SQL en la base de datos SQL Server y obtener los resultados requeridos.

4. Generación de respuestas comprensibles

El *chatbot* debe transformar los datos devueltos en una respuesta textual clara y contextualizada para el usuario.

5. Registro de interacción y trazabilidad

Cada conversación entre el usuario y el *chatbot* debe registrarse (pregunta, consulta SQL generada, respuesta, fecha y hora).

6. Validación de consultas antes de ejecución

El sistema debe verificar que las consultas SQL generadas no contengan errores sintácticos o instrucciones peligrosas (por ejemplo, *DELETE*, *DROP*, *UPDATE*).

7. Manejo de errores y respuestas alternativas

Si la consulta no puede procesarse o la base de datos no devuelve resultados, el *chatbot* debe emitir una respuesta alternativa (“No se encontró información disponible” o “Verifique el nombre del producto”).

8. Filtrado y ordenamiento de datos

El *chatbot* debe permitir que el usuario solicite resultados filtrados u ordenados, como “muéstrame los productos con menos de 5 unidades” o “ordena los productos por fecha de ingreso”.

9. Soporte para consultas condicionales y múltiples criterios

El sistema debe admitir consultas con condiciones compuestas, como “productos con precio mayor a 50 y menos de 10 unidades”.

10. Reconocimiento de sinónimos y contexto

El LLM debe comprender términos equivalentes utilizados por el usuario (“artículo”, “producto”, “ítem”, “*stock*”) y mantener el contexto de la conversación durante la sesión.

11. Actualización dinámica de datos

El *chatbot* debe reflejar los cambios realizados en la base de datos en tiempo real, garantizando que la información mostrada sea siempre actualizada y consistente.

12. Mantenimiento de sesión y contexto conversacional

El *chatbot* debe conservar el contexto de la conversación durante una sesión activa, recordando las consultas previas realizadas por el usuario para ofrecer respuestas más coherentes y continuas. Por ejemplo, si el usuario pregunta “¿Cuántas unidades hay del producto X?” y luego escribe “¿Y del Y?”, el sistema debe entender que se trata de la misma categoría de información y responder en consecuencia.

En la Tabla 10 se presenta el resumen de los requerimientos funcionales del sistema, junto con su respectivo código y descripción.

Tabla 10
Requerimientos Funcionales del Sistema

Código	Requerimiento Funcional	Descripción
RF-01	Procesamiento de consultas en lenguaje natural	Interpreta preguntas del usuario relacionadas con el inventario.
RF-02	Generación automática de consultas SQL	Convierte las solicitudes del usuario en sentencias SQL válidas.
RF-03	Ejecución y recuperación de resultados	Conecta con SQL Server, ejecuta la consulta y devuelve los resultados.
RF-04	Generación de respuestas comprensibles	Presenta los resultados de forma textual y contextual.
RF-05	Registro de interacción y trazabilidad	Guarda las conversaciones y resultados para seguimiento.
RF-06	Validación de consultas antes de ejecución	Evita la ejecución de sentencias erróneas o potencialmente dañinas.

Tabla 10 (continuación)

Código	Requerimiento Funcional	Descripción
RF-07	Manejo de errores y respuestas alternativas	Informa al usuario cuando no se puede completar una solicitud.
RF-08	Filtrado y ordenamiento de datos	Permite obtener listados según condiciones y criterios definidos.
RF-09	Soporte para consultas condicionales múltiples	Acepta consultas con varios parámetros o condiciones combinadas.
RF-10	Reconocimiento de sinónimos y contexto	Comprende términos equivalentes y mantiene el hilo de la conversación.
RF-11	Actualización dinámica de datos	Refleja en tiempo real los cambios registrados en la base de datos.
RF-12	Mantenimiento de sesión y contexto conversacional	Conserva la coherencia de las respuestas recordando las consultas previas del usuario.

Nota. Elaboración Propia.

4.2.2. Requerimientos No Funcionales

1. Rendimiento del sistema

El *chatbot* debe procesar las consultas del usuario y devolver una respuesta en un tiempo máximo de tres segundos, siempre que la conexión con la base de datos esté disponible y estable.

2. Escalabilidad

El sistema debe estar diseñado de manera modular, permitiendo la integración futura de nuevas funciones o la ampliación del conjunto de datos sin afectar su rendimiento general.

3. Confiabilidad

El *chatbot* debe ofrecer un nivel alto de confiabilidad, evitando fallos críticos en la conexión con el modelo LLM o con la base de datos SQL Server durante la ejecución de consultas.

4. Seguridad de acceso

El sistema debe proteger la conexión con la base de datos mediante credenciales seguras y restringir la ejecución de instrucciones que puedan alterar o eliminar datos sensibles (por ejemplo, *DROP*, *DELETE*, *UPDATE*).

5. Privacidad de la información

Los registros de interacción (logs) deben almacenar únicamente información relevante para el análisis de desempeño, evitando guardar datos personales o sensibles de los usuarios.

6. Compatibilidad del entorno

El *chatbot* debe ser compatible con entornos de ejecución basados en Python 3.10 o superior, SQL Server 2019 y sistemas operativos Windows o Linux, garantizando su portabilidad entre diferentes equipos.

7. Usabilidad e interfaz intuitiva

La interacción con el *chatbot* debe ser sencilla, utilizando un formato de texto claro y conversacional. El sistema debe ofrecer respuestas comprensibles sin requerir conocimientos técnicos de programación o bases de datos.

8. Mantenibilidad

El código fuente del *chatbot* debe estar documentado y estructurado de forma modular, permitiendo su mantenimiento, corrección de errores y mejora futura sin comprometer la estabilidad del sistema.

9. Disponibilidad del servicio

El sistema debe mantenerse operativo durante el horario de uso establecido por las MYPES, con una disponibilidad mínima del **95 %**, salvo durante procesos de mantenimiento o actualización programada.

10. Integridad de los datos

El *chatbot* debe garantizar que los datos consultados y presentados sean idénticos a los almacenados en la base de datos, sin alteraciones o pérdidas durante el proceso de consulta y respuesta.

11. Respaldo y recuperación

El sistema debe contar con un procedimiento de respaldo automático de los registros de interacción (logs) y del archivo de configuración, para garantizar la recuperación del servicio ante fallos o pérdidas de información.

12. Adaptabilidad lingüística

El *chatbot* debe permitir ajustes en su modelo de lenguaje para adaptar el vocabulario o tono de las respuestas a distintos tipos de empresas o sectores comerciales sin requerir modificaciones estructurales.

En la Tabla 11 se presenta el resumen estructurado de los requerimientos no funcionales definidos para el sistema, junto con su código y descripción correspondiente.

Tabla 11
Requerimientos No Funcionales del Sistema

Código	Requerimiento No Funcional	Descripción
RNF-01	Rendimiento del sistema	Tiempo máximo de respuesta de tres segundos por consulta.
RNF-02	Escalabilidad	Permite agregar funciones o ampliar datos sin afectar el rendimiento.

Tabla 11 (Continuación)

Código	Requerimiento No Funcional	Descripción
RNF-03	Confiabilidad	Asegura estabilidad en la conexión con el LLM y la base de datos.
RNF-04	Seguridad de acceso	Protege las credenciales y restringe comandos peligrosos.
RNF-05	Privacidad de la información	Limita los datos almacenados a información no sensible.
RNF-06	Compatibilidad del entorno	Funciona en Python 3.10+, SQL Server 2019 y sistemas Windows/Linux.
RNF-07	Usabilidad e interfaz intuitiva	Ofrece una comunicación clara y natural con el usuario.
RNF-08	Mantenibilidad	Código modular y documentado para facilitar actualizaciones.
RNF-09	Disponibilidad del servicio	Operatividad mínima del 95 % durante su horario de uso.
RNF-10	Integridad de los datos	Asegura que los datos mostrados coincidan con los originales.
RNF-11	Respaldo y recuperación	Guarda respaldos automáticos de configuración y logs.
RNF-12	Adaptabilidad lingüística	Permite ajustar el lenguaje del <i>chatbot</i> a distintos contextos empresariales.

Nota. Elaboración Propia.

4.3. Arquitectura del Sistema Propuesto

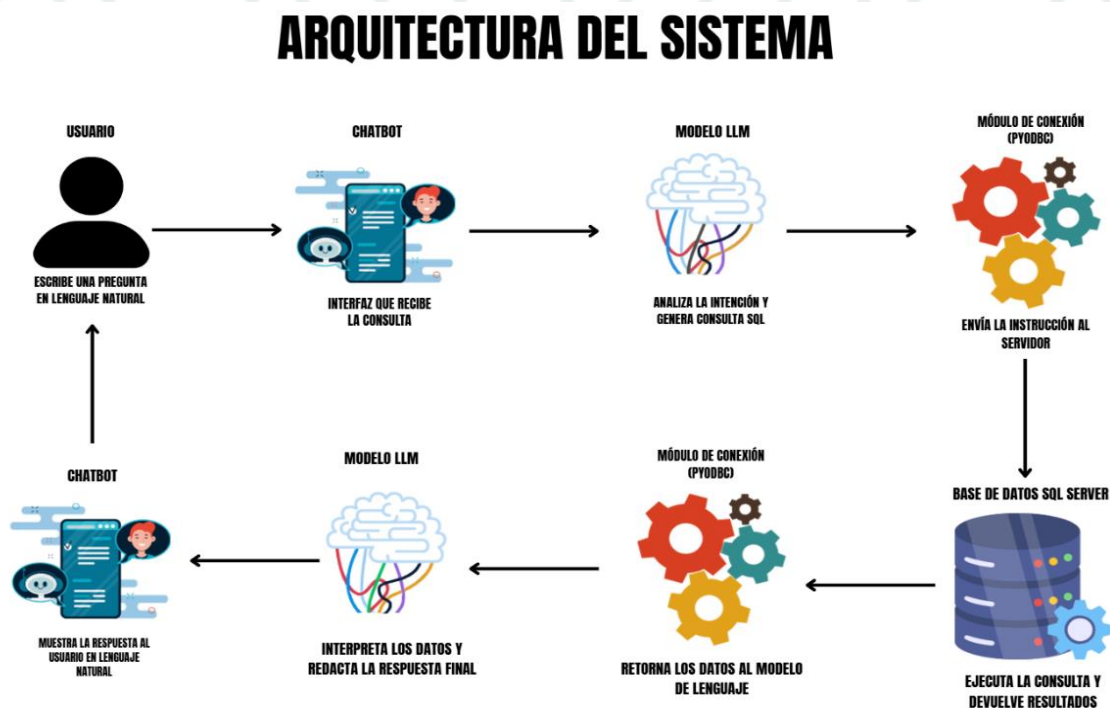
La arquitectura del sistema propuesto se diseñó bajo un enfoque modular y funcional, orientado a permitir la comunicación fluida entre el usuario, el *chatbot* y la base de datos. El sistema emplea un modelo de lenguaje de gran escala (LLM) como componente central de procesamiento, encargado de interpretar las preguntas formuladas en lenguaje natural y transformarlas en consultas SQL estructuradas que son ejecutadas directamente en el servidor de base de datos SQL Server.

Esta arquitectura posibilita la interacción Usuario ↔ *Chatbot* ↔ LLM ↔ Base de datos SQL Server, conformando un circuito cerrado que garantiza precisión en las respuestas y eficiencia en el intercambio de información. Además, esta arquitectura permite controlar el flujo de información entre los componentes, ya que las consultas generadas por el modelo son procesadas antes de su ejecución en la base de datos.

4.3.1. Diagrama de arquitectura

Figura 4

Arquitectura general del sistema propuesto



Nota. Elaboración Propia.

La Figura 4 muestra la arquitectura general del sistema, en la que se observa la secuencia de interacción desde el ingreso de una consulta por parte del usuario hasta la entrega de la respuesta final.

En la figura, el flujo inicia con la consulta en lenguaje natural del usuario, la cual es enviada al *chatbot*, que actúa como interfaz principal. El texto es procesado por el modelo LLM, el cual analiza la intención de la consulta y genera una instrucción SQL que se transmite al módulo de conexión (pyodbc). Este módulo envía la consulta al servidor SQL Server, donde se ejecuta y se obtiene la información requerida. Posteriormente, los resultados retornan al modelo LLM, que los interpreta y genera una respuesta textual óptima, la cual es mostrada nuevamente al usuario mediante el *chatbot*.

4.3.2. Explicación de los módulos

El sistema se compone de cuatro módulos principales que interactúan entre sí para garantizar el correcto flujo de información entre el usuario, el modelo de lenguaje y la base de datos.

a) Chatbot – Capa de lenguaje natural

Corresponde a la interfaz de comunicación con el usuario. Este módulo permite ingresar preguntas en lenguaje natural y visualizar las respuestas generadas.

Su función principal es recibir el texto, enviarlo al modelo LLM para su procesamiento y luego mostrar la respuesta en un formato comprensible y conversacional.

El *chatbot* actúa como intermediario directo entre el usuario y el sistema, eliminando la necesidad de interactuar con bases de datos o comandos técnicos.

b) Modelo LLM (Lenguaje Natural y Generador de Consultas SQL)

Es el núcleo inteligente del sistema. Este módulo interpreta las consultas ingresadas, comprende su contexto semántico y genera la instrucción SQL correspondiente para obtener la información requerida. El modelo LLM está diseñado para comprender sinónimos, mantener el

contexto de la conversación y redactar respuestas coherentes. Además, se encarga de interpretar los resultados devueltos por la base de datos, traduciendo datos estructurados en frases naturales comprensibles para el usuario.

c) Módulo de conexión a SQL Server (pyodbc)

Este componente actúa como puente técnico entre el modelo de lenguaje y la base de datos. Su función es establecer la conexión mediante la librería *pyodbc* de Python, ejecutar la instrucción SQL generada por el LLM y devolver los resultados al modelo.

El módulo garantiza la seguridad y estabilidad de la conexión, evitando la ejecución de sentencias no autorizadas y gestionando los errores de comunicación o sintaxis.

d) Base de datos SQL Server

La base de datos constituye el repositorio estructurado de toda la información del inventario. Contiene tablas relacionadas con productos, *stock*, categorías y transacciones.

Su función dentro de la arquitectura es recibir las consultas SQL generadas, procesarlas y devolver los resultados al módulo de conexión. Los datos almacenados son los que el *chatbot* utiliza para responder con precisión a las preguntas del usuario.

4.3.3. Interacción general del sistema

El proceso completo de interacción puede describirse en las siguientes etapas secuenciales:

1. El usuario formula una pregunta en lenguaje natural.
2. El *chatbot* recibe la consulta y la envía al modelo LLM.
3. El LLM analiza la intención de la pregunta y genera una instrucción SQL.
4. La instrucción SQL se transmite al módulo de conexión *pyodbc*.
5. La base de datos SQL Server ejecuta la consulta y devuelve los resultados.
6. El LLM interpreta los datos devueltos y redacta una respuesta textual.
7. El *chatbot* muestra la respuesta final al usuario.

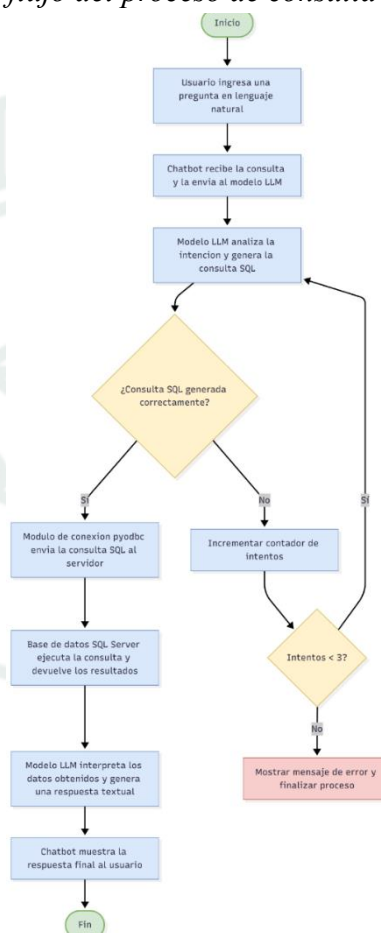
Este flujo garantiza una comunicación continua y bidireccional, donde la precisión técnica del SQL se combina con la naturalidad del lenguaje humano, facilitando la toma de decisiones rápidas y basadas en datos.

4.4. Diseño del Sistema

El diseño del sistema representa la etapa de estructuración funcional y visual del *chatbot*, donde se definen los procesos, interacciones y componentes que intervienen en la comunicación entre el usuario, el modelo de lenguaje (LLM) y la base de datos SQL Server. El objetivo principal del diseño es establecer el flujo lógico de consultas, los casos de uso esenciales, y la interfaz conversacional, asegurando una experiencia de usuario fluida y coherente con los objetivos de la propuesta tecnológica.

4.4.1. Diagramas de flujo del proceso de consulta.

Figura 5
Diagrama de flujo del proceso de consulta



Nota. Elaboración Propia.

El diagrama de flujo que se muestra en la Figura 5 detalla las etapas que se ejecutan desde el momento en que el usuario realiza una pregunta hasta que el sistema devuelve la respuesta final. El flujo incluye la interpretación del lenguaje natural, la generación de la consulta SQL, la comunicación con la base de datos y la formulación de la respuesta textual.

4.4.2. Casos de uso principales:

Los casos de uso permiten representar de forma esquemática las interacciones entre el usuario y el *chatbot*, definiendo los escenarios que describen cómo se utiliza el sistema para cumplir sus funciones principales.

En este proyecto, existe un único actor: el usuario general, quien interactúa directamente con el *chatbot* mediante lenguaje natural para consultar la información almacenada en la base de datos SQL Server.

- **Casos de uso identificados:**

Los principales casos de uso definidos para el sistema se presentan en la Tabla 12, donde se especifica el código asignado, el nombre del caso de uso y una breve descripción de su funcionalidad. Estos casos de uso permiten representar de manera ordenada el flujo principal de interacción entre el usuario y el sistema, desde el ingreso de la consulta hasta la presentación de la respuesta final.

Además, evidencian la participación de los componentes principales del sistema como el *chatbot*, el modelo LLM y la base de datos SQL Server, asegurando que cada etapa del proceso aporte al apoyo de la toma de decisiones en la gestión de inventarios.

Tabla 12
Casos de uso identificados

Código	Caso de Uso	Descripción
CU-01	Ingresar consulta	El usuario formula una pregunta en lenguaje natural relacionada con el inventario.
CU-02	Procesar consulta	El <i>chatbot</i> analiza la consulta y la envía al modelo LLM para su interpretación.
CU-03	Generar instrucción SQL	El modelo LLM transforma la solicitud del usuario en una consulta SQL válida.
CU-04	Ejecutar consulta	El sistema ejecuta la instrucción SQL en la base de datos SQL Server.
CU-05	Obtener resultados	La base de datos devuelve los datos solicitados.
CU-06	Generar respuesta textual	El modelo LLM interpreta los resultados y redacta una respuesta clara.
CU-07	Mostrar respuesta	El <i>chatbot</i> presenta la respuesta final al usuario en lenguaje natural.
CU-08	Registrar interacción	El sistema guarda la consulta, la respuesta y la fecha de la conversación para control y trazabilidad.

Nota. Elaboración Propia.

La Figura 6 muestra el Caso de Uso CU-01, y la Tabla 13 presenta su ficha, donde se describe cómo el usuario ingresa una consulta en lenguaje natural relacionada con el inventario.

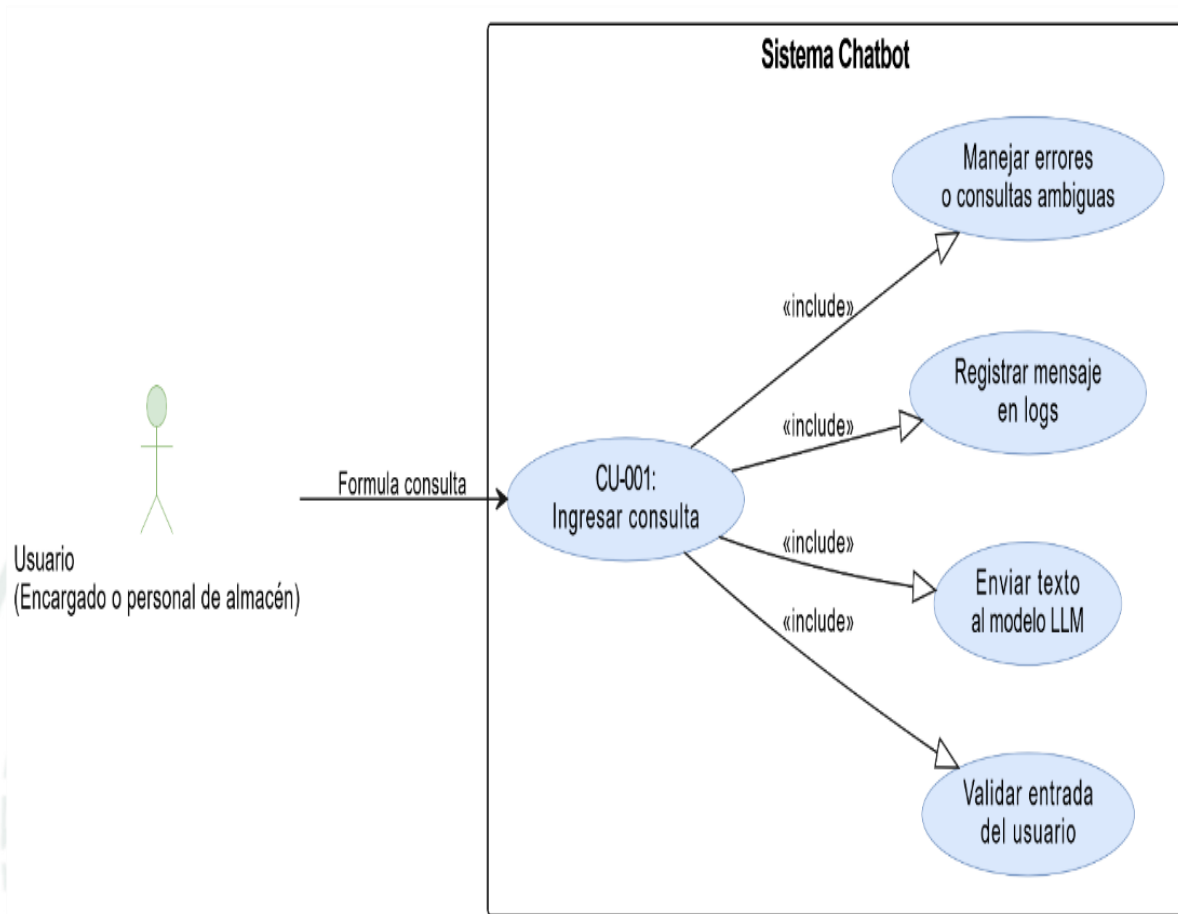
Este caso de uso representa el punto de inicio de la interacción con el sistema, ya que permite que el encargado o personal de almacén formule preguntas sobre productos, *stock*, entradas, salidas o necesidades de reposición.

Tabla 13
Caso de Uso CU-01

Código:	CU-001	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Ingresar consulta		
Descripción:	<p>Permitir que el usuario formule preguntas en lenguaje natural relacionadas con el inventario (por ejemplo: “¿Cuántas unidades quedan del producto X?”).</p> <p>El <i>chatbot</i> debe recibir el texto y enviarlo al modelo LLM para su interpretación.</p>		
Entrada:	Pregunta en lenguaje natural escrita por el usuario.	Salida:	Consulta enviada correctamente al modelo LLM.
Observaciones:	<ul style="list-style-type: none"> • El <i>chatbot</i> debe aceptar texto libre escrito por el usuario. • Se validará que la entrada no esté vacía. • El <i>chatbot</i> podrá sugerir ejemplos de consulta si el texto es confuso o incompleto. • El mensaje ingresado se almacenará en un registro de logs con fecha y hora de la interacción. 		
Criterios de Aceptación:			
Quando	Espero		
El usuario escribe una consulta válida	El <i>chatbot</i> la recibe y la envía al modelo LLM para su interpretación.		
El usuario deja el campo vacío	El <i>chatbot</i> muestra el mensaje “Por favor, ingrese una consulta válida”.		
El usuario realiza una consulta ambigua	El <i>chatbot</i> sugiere ejemplos o reformula la pregunta para clarificar la intención.		

Nota. Elaboración Propia.

Figura 6
Diagrama Caso de Uso CU-01



Nota. Elaboración Propia.

En este caso de uso se consideran acciones complementarias necesarias para asegurar una interacción adecuada, como la validación del texto ingresado, el registro del mensaje en logs, el envío de la consulta al modelo LLM y el manejo de errores o consultas ambiguas. Estos elementos permiten que el sistema procese correctamente la solicitud antes de continuar con las siguientes etapas del flujo.

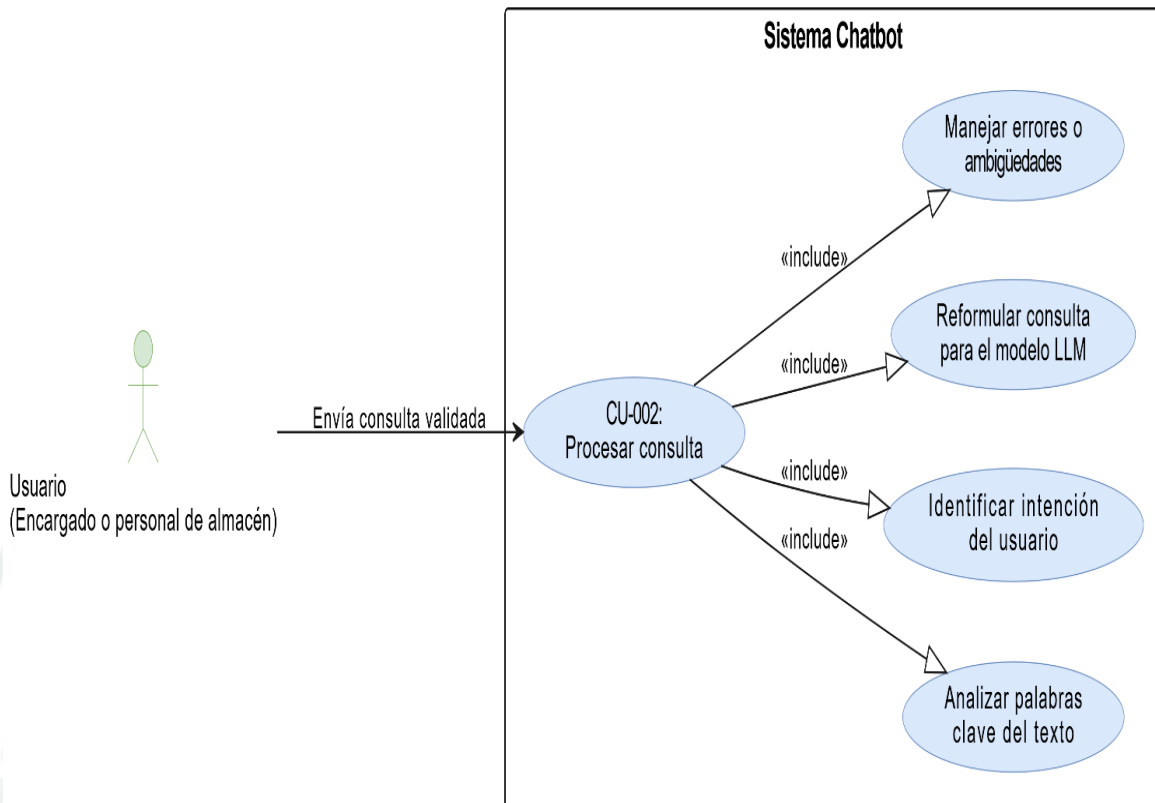
En la Tabla 14 se presenta la ficha del Caso de Uso CU-02, el cual describe el procesamiento interno de la consulta del usuario, donde el *chatbot* analiza la intención del mensaje y lo prepara para ser enviado al modelo LLM como se muestra en la Figura 7.

Tabla 14
Caso de Uso CU-02

Código:	CU-002	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Procesar consulta		
Descripción:	Analizar la consulta del usuario y enviarla al modelo LLM para su comprensión semántica. El <i>chatbot</i> identifica las palabras clave, interpreta la intención del usuario y organiza la consulta antes de transferirla al modelo LLM, asegurando que el texto sea legible y procesable.		
Entrada:	Pregunta validada proveniente del usuario.	Salida:	Solicitud enviada correctamente al modelo de lenguaje para la generación de la instrucción SQL.
Observaciones:	<ul style="list-style-type: none"> •El chatbot analiza las palabras clave dentro del texto recibido. • El chatbot reformula internamente el texto para facilitar la comprensión del modelo LLM. •El chatbot identifica la intención de la consulta (por ejemplo: <i>stock</i>, productos, precios y fechas) • Si la consulta es ambigua, el chatbot solicitará al usuario que proporcione más detalles o reformule la pregunta. 		
Criterios de Aceptación:			
Cuando	Espero		
El usuario envía una consulta clara	El <i>chatbot</i> procesa correctamente el texto y lo envía al modelo LLM.		
El usuario envía una consulta ambigua	El <i>chatbot</i> solicita al usuario que aclare o amplíe su pregunta.		
El usuario envía una consulta con errores o símbolos no válidos	El <i>chatbot</i> muestra el mensaje “No se puede procesar la consulta. Por favor, revise el formato del texto.”		

Nota. Elaboración Propia.

Figura 7
Diagrama Caso de Uso CU-02



Nota. Elaboración Propia.

En este caso de uso se consideran acciones internas necesarias para preparar correctamente la consulta antes de su procesamiento por el modelo LLM.

Entre ellas se incluye el análisis de palabras clave, la identificación de la intención del usuario, la reformulación del texto cuando sea necesario y el manejo de errores o ambigüedades. Esto permite que la solicitud sea más clara, estructurada y adecuada para continuar con las siguientes etapas del sistema.

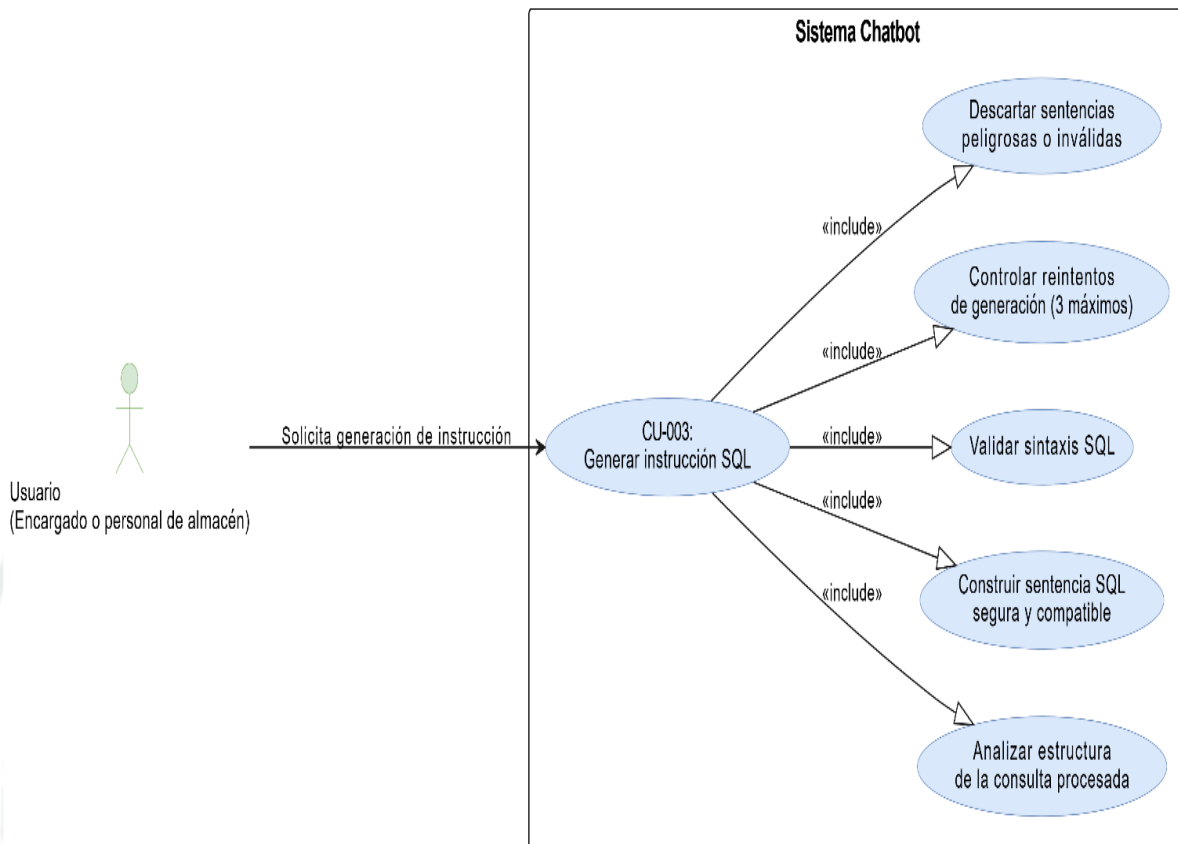
La Tabla 15 presenta la ficha del Caso de Uso CU-03, donde se describe cómo el *chatbot* genera una instrucción SQL segura a partir de la consulta procesada por el modelo LLM como se muestra en la Figura 8.

Tabla 15
Caso de Uso CU-03

Código:	CU-003	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Generar instrucción SQL		
Descripción:	El <i>chatbot</i> , con apoyo del modelo LLM, transforma la consulta en lenguaje natural ingresada por el usuario en una instrucción SQL estructurada y válida. La instrucción generada debe ser compatible con la base de datos SQL Server y contener únicamente operaciones de lectura, sin alterar los datos almacenados.		
Entrada:	Consulta procesada y estructurada por el modelo LLM.	Salida:	Instrucción SQL generada y lista para ejecución.
Observaciones:	<ul style="list-style-type: none"> • El chatbot debe generar únicamente sentencias SQL seguras (SELECT). • Se validará que la estructura de la consulta sea correcta antes de enviarla al servidor. • Si la generación falla, se intentará nuevamente hasta tres veces. • Se bloqueará cualquier instrucción con sintaxis no permitida o palabras reservadas como DROP, DELETE, UPDATE o INSERT. 		
Criterios de Aceptación:			
Cuando	Espero		
El modelo LLM recibe una consulta válida	El <i>chatbot</i> genera una instrucción SQL estructurada y sintácticamente correcta.		
El modelo LLM no logra generar una instrucción SQL válida en el primer intento	El <i>chatbot</i> reintenta la generación hasta tres veces.		
El modelo LLM detecta una instrucción peligrosa o con errores de sintaxis	El <i>chatbot</i> descarta la instrucción y muestra un mensaje de advertencia.		

Nota. Elaboración Propia.

Figura 8
 Diagrama Caso de Uso CU-03



Nota. Elaboración Propia.

En este caso de uso se consideran mecanismos de control necesarios para asegurar que la instrucción SQL generada sea segura y funcional.

Para ello, el sistema analiza la estructura de la consulta procesada, construye una sentencia compatible con SQL Server, valida su sintaxis y descarta instrucciones peligrosas o no permitidas. Asimismo, se contempla un límite de reintentos de generación, con el fin de evitar respuestas incorrectas y mantener un flujo controlado dentro del sistema.

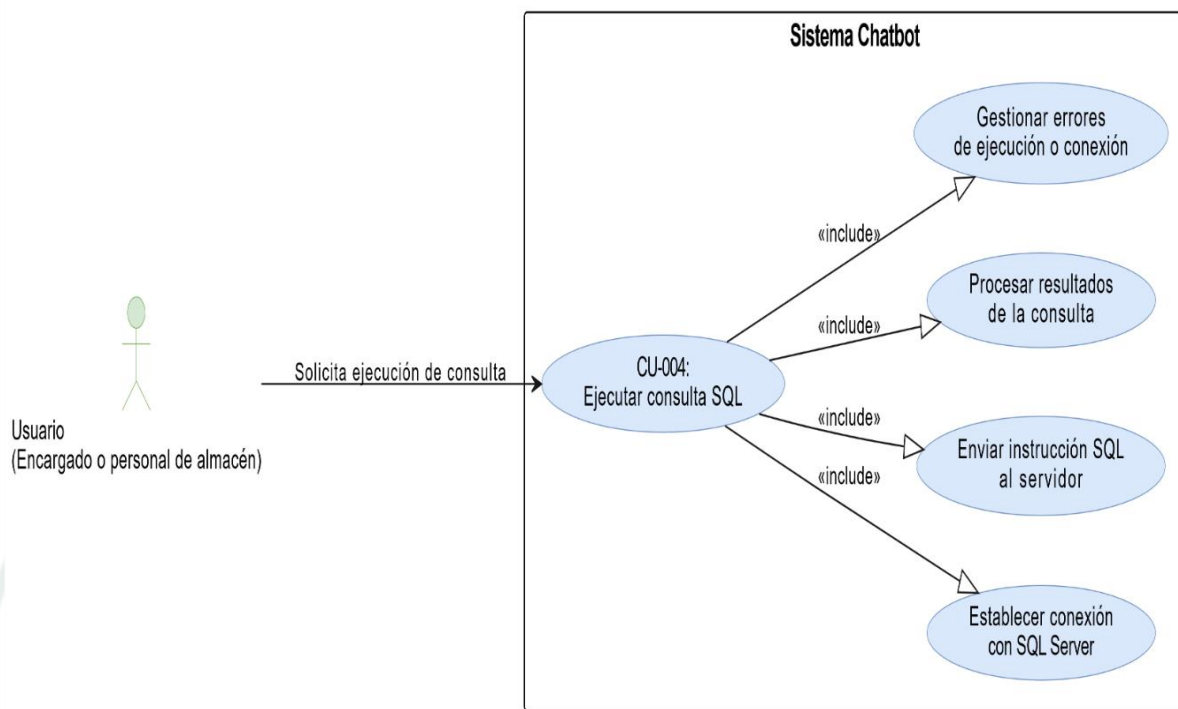
La Tabla 16 presenta la ficha del Caso de Uso CU-04, donde se describe cómo el *chatbot* ejecuta la instrucción SQL en la base de datos y recupera los resultados como se muestra en la Figura 9.

Tabla 16*Caso de Uso CU-04*

Código:	CU-004	Prioridad:	Alta								
Actor:	Usuario (encargado o personal de almacén)										
Nombre del Requerimiento:	Ejecutar consulta SQL										
Descripción:	El <i>chatbot</i> envía la instrucción SQL generada al servidor de base de datos SQL Server para su ejecución. El sistema debe establecer una conexión segura, procesar la consulta y recuperar los resultados solicitados. Los datos obtenidos se utilizarán posteriormente para que el modelo LLM formule una respuesta en lenguaje natural.										
Entrada:	Instrucción SQL generada por el modelo LLM.	Salida:	Resultado de la consulta (filas, valores o registros) devuelto desde la base de datos.								
Observaciones:	<ul style="list-style-type: none"> • La conexión entre el <i>chatbot</i> y la base de datos se realiza mediante el controlador pyodbc. • Solo se ejecutarán sentencias de lectura (SELECT). • El sistema debe manejar excepciones en caso de error de conexión o tiempo de espera. • Los resultados se retornarán en formato estructurado (JSON o tabla). • Si la base de datos no responde, se notificará al usuario con un mensaje de error. 										
Criterios de Aceptación:	<table border="1"> <thead> <tr> <th>Cuando</th> <th>Espero</th> </tr> </thead> <tbody> <tr> <td>El <i>chatbot</i> envía una instrucción SQL válida</td> <td>El servidor ejecuta la consulta y devuelve los resultados solicitados.</td> </tr> <tr> <td>La instrucción SQL tiene errores de sintaxis o acceso</td> <td>El <i>chatbot</i> informa “Error al ejecutar la consulta, verifique la estructura SQL.”</td> </tr> <tr> <td>El servidor de base de datos no responde</td> <td>El <i>chatbot</i> muestra “No se pudo establecer conexión con la base de datos.”</td> </tr> </tbody> </table>			Cuando	Espero	El <i>chatbot</i> envía una instrucción SQL válida	El servidor ejecuta la consulta y devuelve los resultados solicitados.	La instrucción SQL tiene errores de sintaxis o acceso	El <i>chatbot</i> informa “Error al ejecutar la consulta, verifique la estructura SQL.”	El servidor de base de datos no responde	El <i>chatbot</i> muestra “No se pudo establecer conexión con la base de datos.”
Cuando	Espero										
El <i>chatbot</i> envía una instrucción SQL válida	El servidor ejecuta la consulta y devuelve los resultados solicitados.										
La instrucción SQL tiene errores de sintaxis o acceso	El <i>chatbot</i> informa “Error al ejecutar la consulta, verifique la estructura SQL.”										
El servidor de base de datos no responde	El <i>chatbot</i> muestra “No se pudo establecer conexión con la base de datos.”										

Nota. Elaboración Propia.

Figura 9
Diagrama Caso de Uso CU-04



Nota. Elaboración Propia.

En este caso de uso se consideran mecanismos de control para asegurar que la ejecución de la consulta se realice de forma segura y ordenada. Para ello, el sistema utiliza el controlador pyodbc, valida que solo se ejecuten sentencias de lectura, maneja posibles errores de conexión o sintaxis y retorna los resultados en un formato estructurado.

Esto permite mantener la integridad de la base de datos y garantizar que la información recuperada pueda ser utilizada correctamente en las siguientes etapas del sistema.

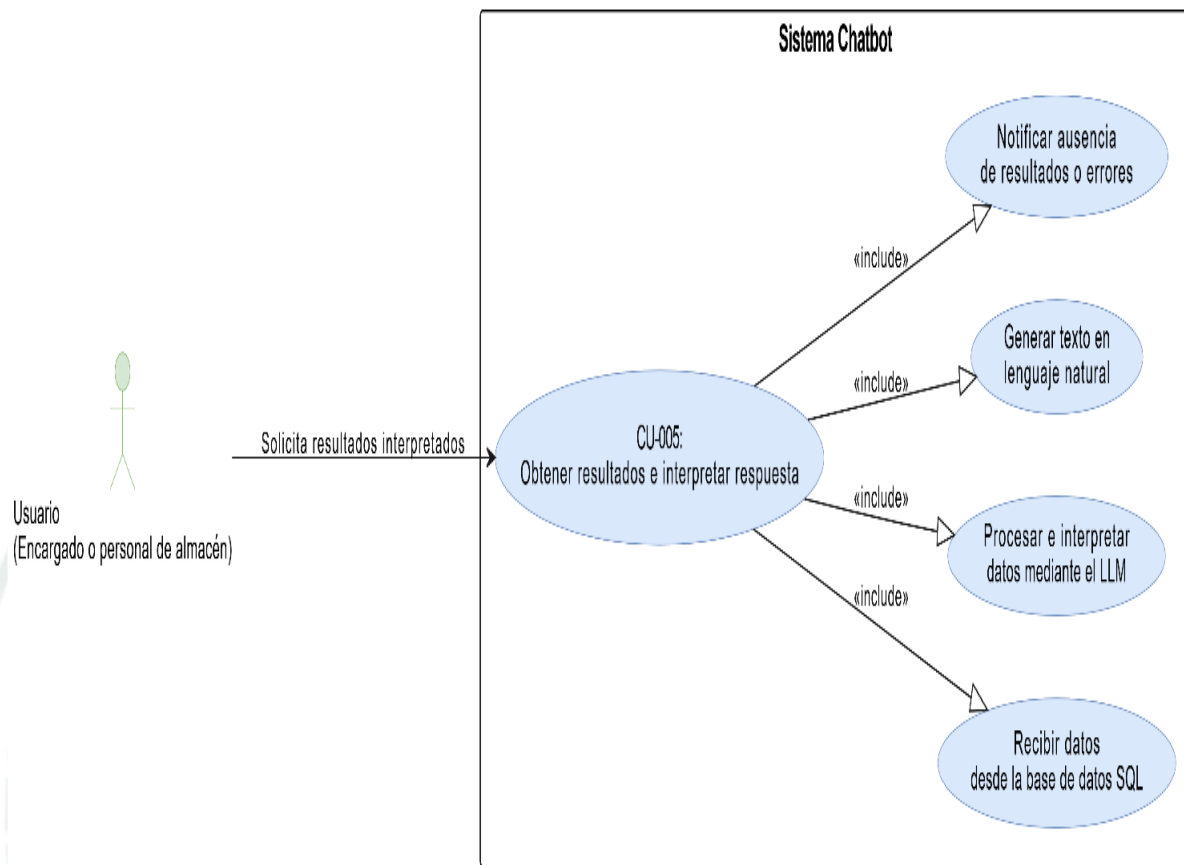
La Tabla 17 presenta la ficha del Caso de Uso CU-05, donde se describe cómo el *chatbot* interpreta los resultados devueltos por la base de datos y genera una respuesta en lenguaje natural como se muestra en la Figura 10.

Tabla 17*Caso de Uso CU-05*

Código:	CU-005	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Obtener resultados e interpretar respuesta		
Descripción:	El <i>chatbot</i> recibe los resultados de la ejecución SQL desde la base de datos, los interpreta mediante el modelo LLM y genera una respuesta en lenguaje natural comprensible para el usuario. El sistema debe asegurar que los datos mostrados sean precisos, contextualizados y coherentes con la consulta inicial.		
Entrada:	Resultados estructurados obtenidos de la base de datos SQL Server.	Salida:	Respuesta final redactada en lenguaje natural presentada al usuario.
Observaciones:	<ul style="list-style-type: none"> • El modelo LLM analiza los datos obtenidos y los convierte en texto explicativo. • El <i>chatbot</i> adapta el formato de salida (texto o tabla) según el tipo de consulta. • Los resultados se almacenarán temporalmente en memoria para trazabilidad. • Si no se obtienen registros, el <i>chatbot</i> debe indicar “No se encontraron resultados para su consulta.” 		
Criterios de Aceptación:			
Cuando	Espero		
El sistema obtiene resultados válidos de la base de datos	El <i>chatbot</i> muestra una respuesta clara y contextual en lenguaje natural.		
El sistema no obtiene registros de la base de datos	El <i>chatbot</i> muestra “No se encontraron resultados para su consulta.”		
Ocurre un error al interpretar los datos	El <i>chatbot</i> muestra “No fue posible procesar los resultados, intente nuevamente.”		

Nota. Elaboración Propia.

Figura 10
 Diagrama Caso de Uso CU-05



Nota. Elaboración Propia.

En este caso de uso se resalta la función interpretativa del sistema, ya que los resultados obtenidos desde la base de datos no se presentan únicamente como registros técnicos, sino como información entendible para el usuario.

Además, se contempla la notificación ante ausencia de resultados o errores, asegurando que la respuesta final sea coherente, útil y adecuada para apoyar la toma de decisiones en la gestión de inventarios.

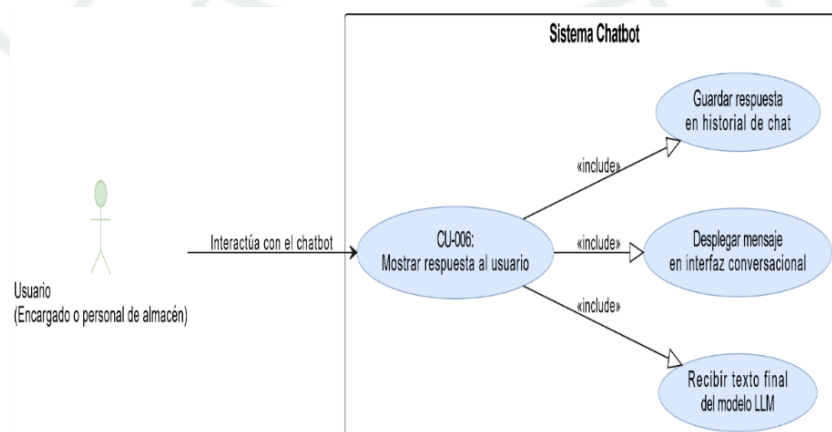
La Tabla 18 muestra la ficha del Caso de Uso CU-06, en la cual se detalla cómo el *chatbot* entrega la respuesta generada por el modelo LLM y la presenta al usuario dentro de la interfaz conversacional como se muestra en la Figura 11.

Tabla 18
Caso de Uso CU-06

Código:	CU-006	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Mostrar respuesta al usuario		
Descripción:	El <i>chatbot</i> presenta al usuario la respuesta textual generada por el modelo LLM en lenguaje natural. El mensaje debe ser claro, relevante y estar contextualizado de acuerdo con la consulta original.		
Entrada:	Respuesta textual generada por el modelo LLM.	Salida:	Respuesta visible en la interfaz del <i>chatbot</i> .
Observaciones:	<ul style="list-style-type: none"> • El <i>chatbot</i> debe mostrar la respuesta dentro del área de conversación en tiempo real. • Si la sesión expira, se solicitará al usuario reiniciar la interacción. • El diseño visual de la respuesta seguirá el formato conversacional de la interfaz. 		
Criterios de Aceptación:			
Cuando	Espero		
El modelo LLM genera la respuesta final	El <i>chatbot</i> la muestra en el área de conversación.		
La respuesta está vacía			
El usuario solicita ver la conversación anterior	El <i>chatbot</i> muestra “No se obtuvo una respuesta válida, intente nuevamente.”		

Nota. Elaboración Propia.

Figura 11
Diagrama Caso de Uso CU-06



Nota. Elaboración Propia.

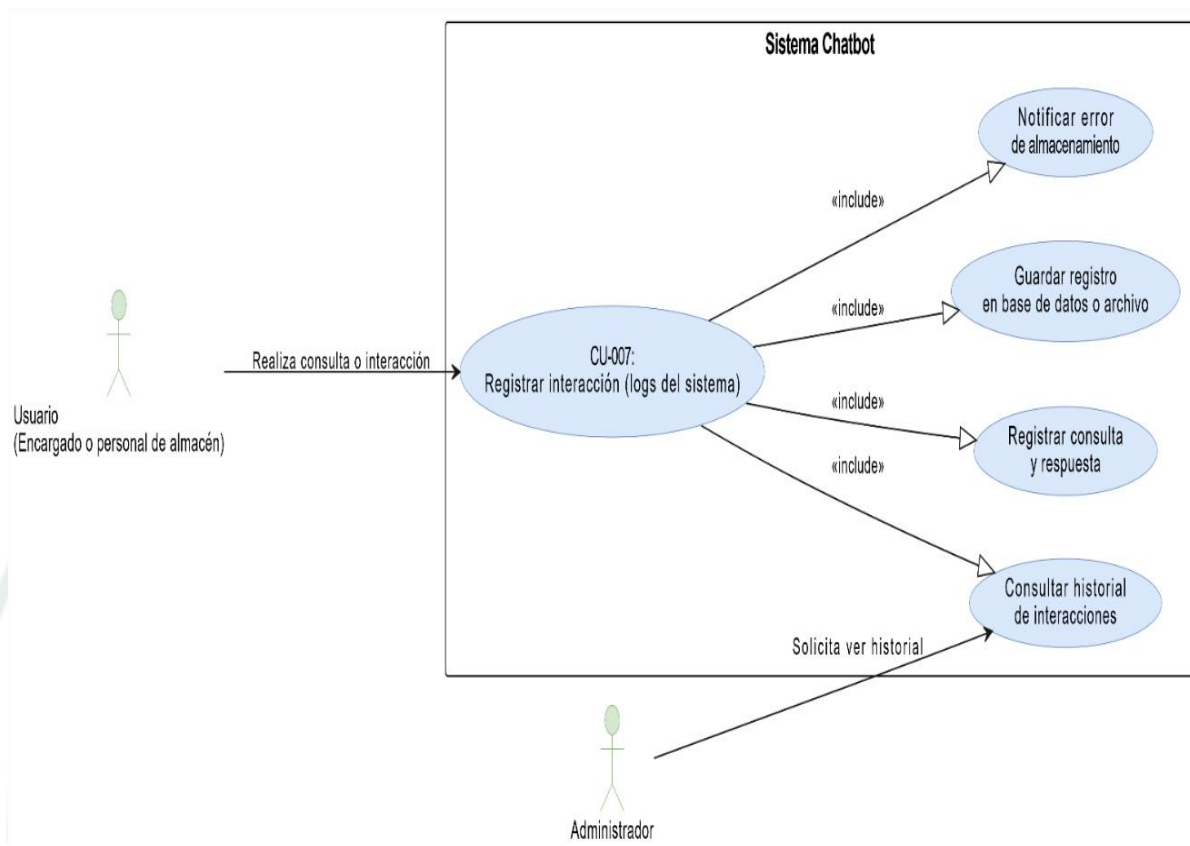
La Tabla 19 presenta la ficha del Caso de Uso CU-07, donde se describe cómo el *chatbot* registra cada interacción en los logs del sistema para asegurar trazabilidad y permitir su revisión posterior como se muestra en la Figura 12.

Tabla 19
Caso de Uso CU-07

Código:	CU-007	Prioridad:	Alta
Actor:	Usuario (encargado o personal de almacén)		
Nombre del Requerimiento:	Registrar interacción (logs del sistema)		
Descripción:	El <i>chatbot</i> registra cada interacción realizada por el usuario en un archivo o base de datos de logs. Este registro incluye la consulta enviada, la respuesta generada, la fecha, la hora y el estado del procesamiento. El objetivo es mantener trazabilidad de las operaciones y permitir auditorías o evaluaciones de desempeño del sistema.		
Entrada:	Datos de la interacción (consulta, respuesta, fecha y hora).	Salida:	Registro almacenado correctamente en el sistema de logs.
Observaciones:	<ul style="list-style-type: none"> • El <i>chatbot</i> debe registrar automáticamente todas las consultas y respuestas generadas. • Los registros incluirán el identificador de sesión y el estado de la interacción (éxito o error). • En caso de error de conexión o almacenamiento, el sistema debe mostrar una advertencia. • Los logs podrán ser consultados por el administrador para análisis posteriores. 		
Criterios de Aceptación:			
Quando	Espero		
Se realiza una consulta y se genera una respuesta	El <i>chatbot</i> registra automáticamente la interacción en los logs.		
Ocurre un error en la conexión de almacenamiento	El <i>chatbot</i> muestra “No se pudo guardar el registro de la interacción.”		
El administrador consulta los registros del sistema	El sistema muestra la lista completa de interacciones con fecha y hora.		

Nota. Elaboración Propia.

Figura 12
Diagrama Caso de Uso CU-07



Nota. Elaboración Propia.

En este caso de uso se considera el almacenamiento automático de las consultas y respuestas generadas durante la interacción con el sistema.

Además, se incluye la posibilidad de consultar el historial de interacciones y notificar errores en caso de fallas de almacenamiento. Esto permite llevar un control ordenado del funcionamiento del *chatbot* y contar con información útil para futuras evaluaciones o mejoras del sistema.

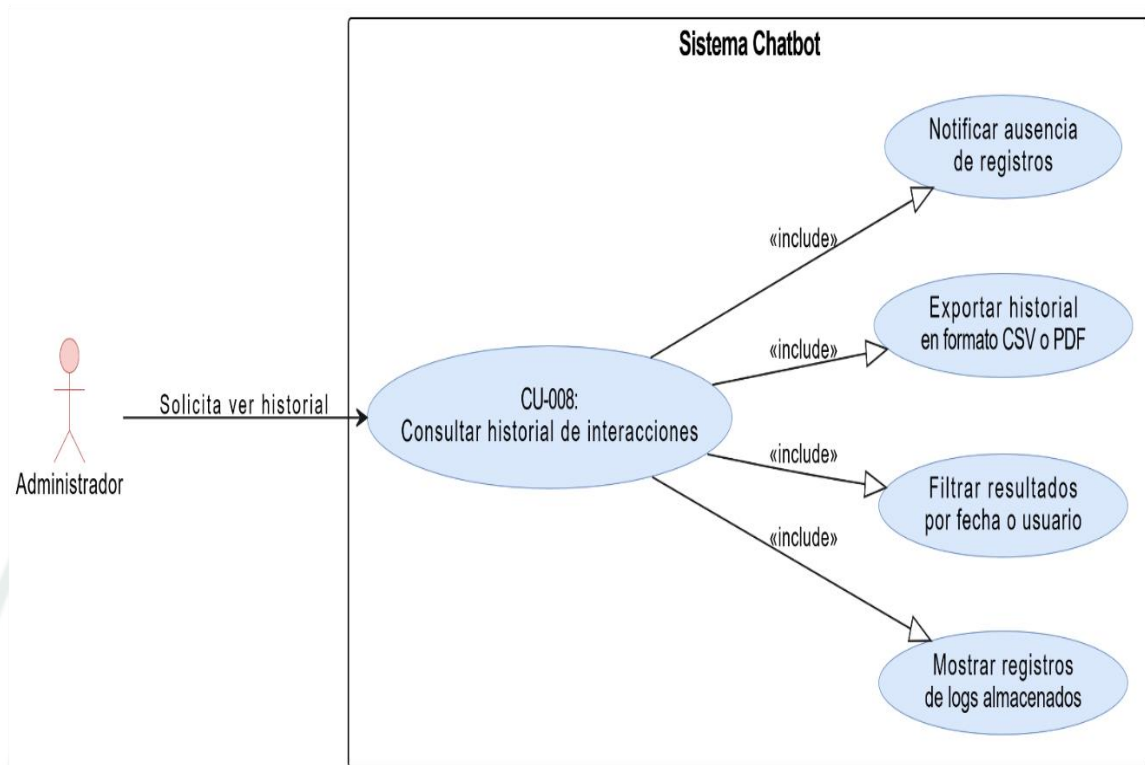
La Tabla 20 presenta la ficha del Caso de Uso CU-08, donde se detalla cómo el administrador consulta el historial de interacciones registradas en el sistema y accede a los logs para su revisión y análisis como se muestra en la Figura 13.

Tabla 20
Caso de Uso CU-08

Código:	CU-008	Prioridad:	Alta
Actor:	Administrador		
Nombre del Requerimiento:	Consultar historial de interacciones		
Descripción:	Permitir que el administrador consulte el historial completo de interacciones registradas en el sistema. El módulo mostrará los registros almacenados en los logs del <i>chatbot</i> , incluyendo las consultas realizadas por los usuarios, las respuestas generadas, la fecha, la hora y el estado de procesamiento.		
Entrada:	Solicitud del administrador para visualizar el historial de interacciones.	Salida:	Listado de registros de logs visualizados correctamente.
Observaciones:	<ul style="list-style-type: none"> • Solo los usuarios con rol de administrador podrán acceder a esta funcionalidad. • El sistema debe permitir aplicar filtros de búsqueda por fecha, usuario o tipo de resultado. • Si no existen registros, el sistema mostrará el mensaje “No se encontraron interacciones registradas.” • El historial podrá exportarse en formato CSV o PDF. 		
Criterios de Aceptación:			
Cuando	Espero		
El administrador accede al módulo de historial	El sistema muestra todas las interacciones registradas con fecha, hora y usuario.		
El administrador aplica un filtro de búsqueda	El sistema muestra únicamente los resultados que cumplen con los criterios especificados.		
No existen registros disponibles	El sistema muestra “No se encontraron interacciones registradas.”		

Nota. Elaboración Propia.

Figura 13
Diagrama Caso de Uso CU-08



Nota. Elaboración Propia.

4.4.3. Boceto de la interfaz del *Chatbot*.

El diseño de la interfaz del *chatbot* se elaboró con el propósito de ofrecer una experiencia de uso intuitiva, minimalista y funcional, enfocada en la simplicidad y la eficiencia en la comunicación entre el usuario y el sistema.

La interfaz propuesta se basa en un entorno web accesible desde cualquier navegador, con una estructura visual que prioriza la claridad del diálogo y la facilidad de interacción.

El prototipo fue diseñado mediante la herramienta Balsamiq Mockups, representando tres escenarios distintos de interacción entre el usuario y el *chatbot*:

- Inicio de conversación.
- Consulta exitosa.
- Mensaje de error ante consulta no válida.

a. Elementos principales de la interfaz

La interfaz propuesta se compone de los siguientes componentes:

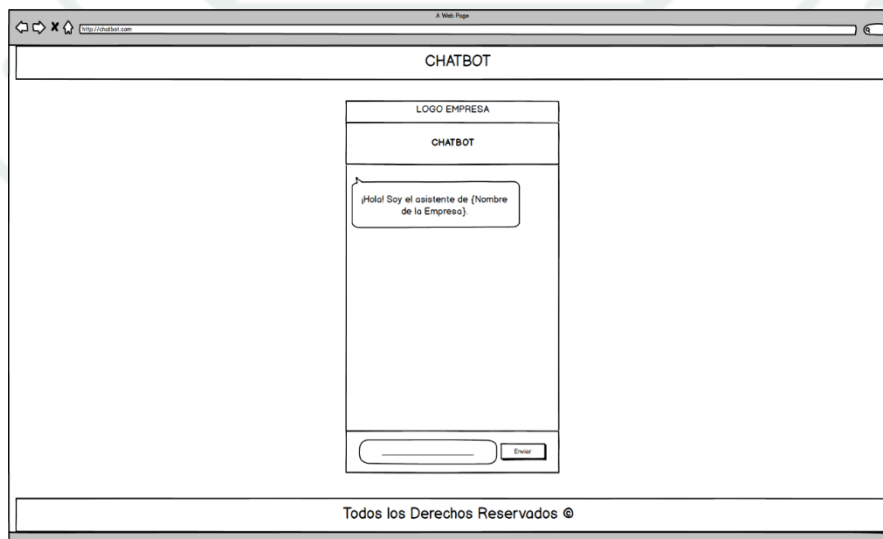
1. **Encabezado principal:** contiene el título “*CHATBOT*” y el logotipo de la empresa, lo que brinda identidad corporativa al sistema.
2. **Área de conversación:** muestra los mensajes del usuario y las respuestas generadas por el *chatbot*. Se utiliza un formato de burbujas para distinguir fácilmente los roles de emisor y receptor.
3. **Campo de entrada de texto:** permite al usuario escribir preguntas en lenguaje natural relacionadas con el inventario.
4. **Botón de envío:** activa el procesamiento de la consulta, enviando el texto al modelo de lenguaje (LLM) para su interpretación y generación de la instrucción SQL.
5. **Pie de página:** incluye un mensaje institucional o de derechos reservados, que refuerza la identidad del sistema.

b. Escenarios representados en los bocetos

En la Figura 14, el *chatbot* presenta la pantalla inicial de conversación, donde muestra un mensaje de bienvenida:

Figura 14

Boceto de la interfaz del chatbot – Inicio de conversación.



Nota. Elaboración Propia.

Luego en la Figura 15, se ilustra una interacción exitosa, en la que el usuario formula una pregunta válida, por ejemplo:

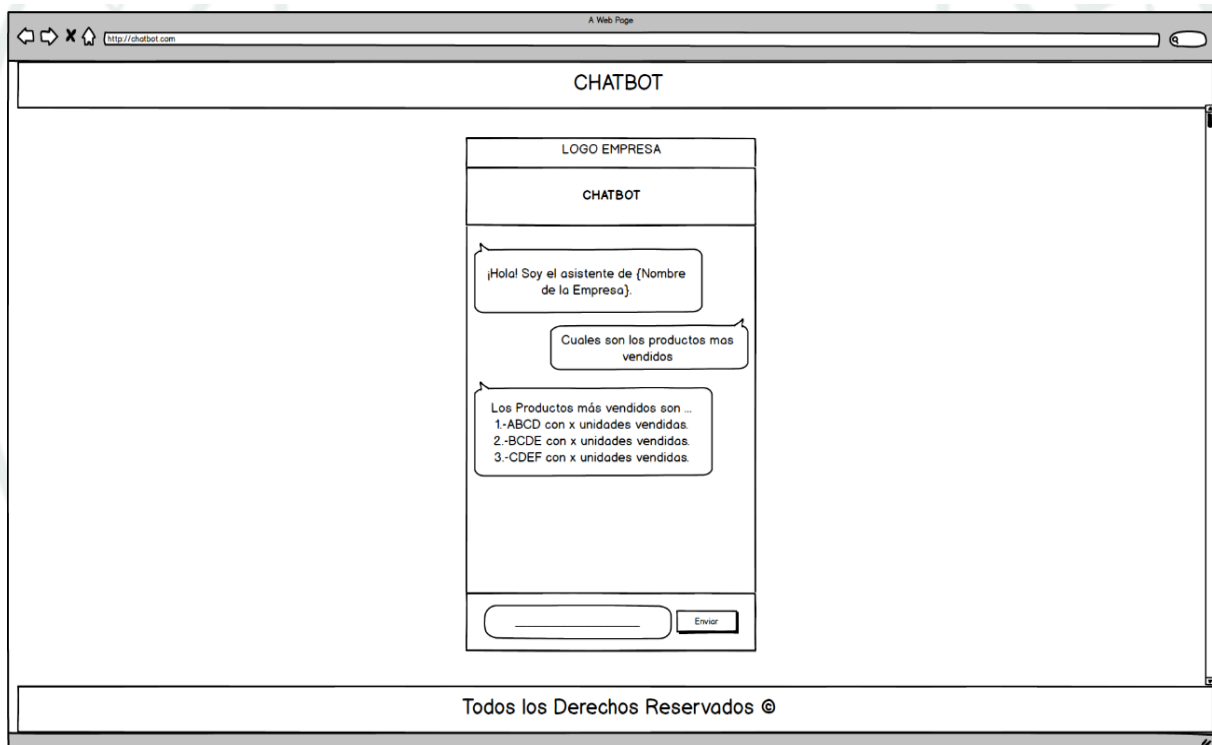
“¿Cuáles son los productos más vendidos?”

El *chatbot* procesa la solicitud, genera la instrucción SQL correspondiente, la ejecuta en la base de datos SQL Server y devuelve una respuesta con los productos más vendidos y sus respectivas unidades.

Este escenario demuestra la capacidad del sistema para comprender el lenguaje natural y devolver información precisa desde la base de datos.

Figura 15

Boceto de la interfaz del chatbot – Ejemplo de consulta exitosa.



Nota. Elaboración Propia.

Finalmente, la Figura 16 muestra un caso de manejo de error o excepción, cuando el *chatbot* no logra generar o ejecutar una instrucción SQL válida después de tres intentos.

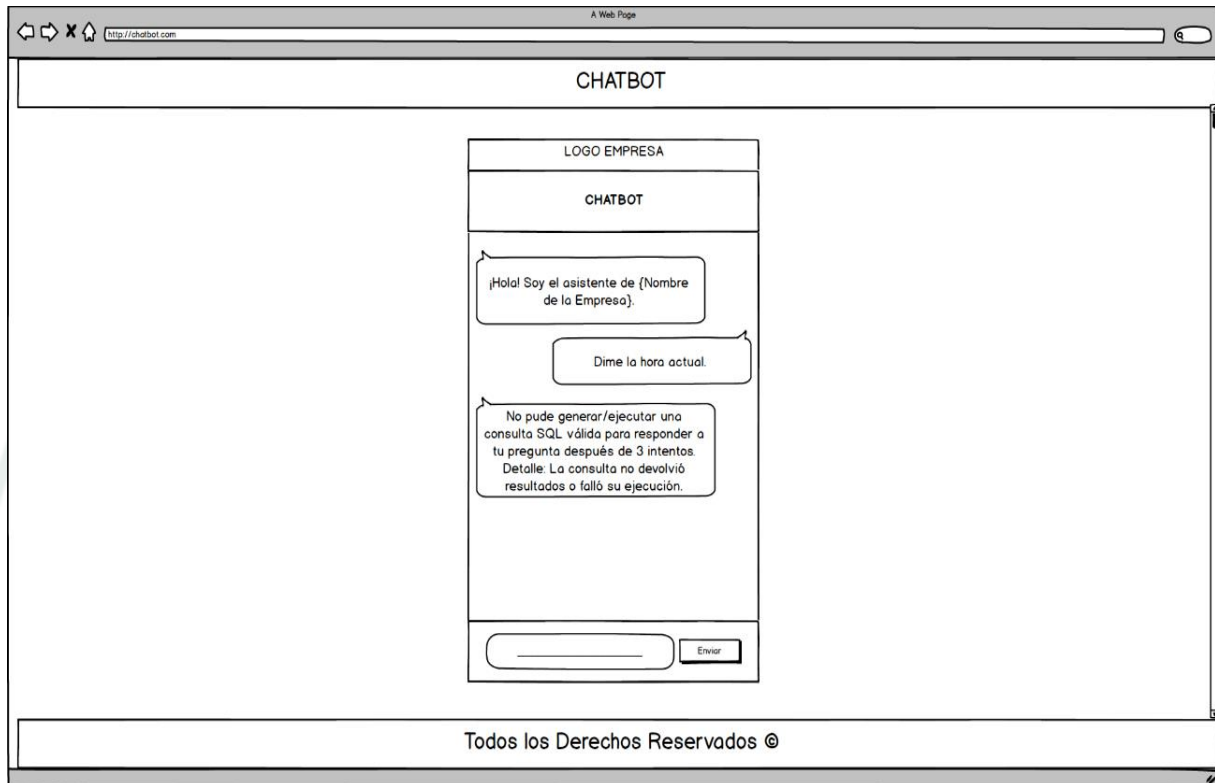
El sistema responde con un mensaje informativo, evitando confundir al usuario:

“No pude generar/ejecutar una consulta SQL válida para responder a tu pregunta después de 3 intentos. Detalle: la consulta no devolvió resultados o falló su ejecución.”

Este comportamiento evidencia que el sistema está diseñado para mantener una comunicación clara y transparente, incluso ante fallas o entradas ambiguas.

Figura 16

Boceto de la interfaz del chatbot – Manejo de error o excepción.



Nota. Elaboración Propia.

4.5. Desarrollo e Implementación bajo SCRUM

4.5.1. *Sprint 1* – Configuración del entorno y conexión de datos

Durante el *Sprint 1*, se realizó la configuración del entorno de desarrollo y la integración inicial entre Python y el servidor de base de datos SQL Server, garantizando la comunicación correcta entre ambas plataformas. El objetivo de este *sprint* fue preparar la infraestructura técnica sobre la cual se construirá el *chatbot*, asegurando la conectividad estable y la estructura de datos necesaria para el procesamiento de consultas.

a) Creación y configuración de la base de datos

Se implementó una base de datos denominada BI_SAVEC, alojada en SQL Server 2019, que contiene las tablas principales del dominio de inventario:

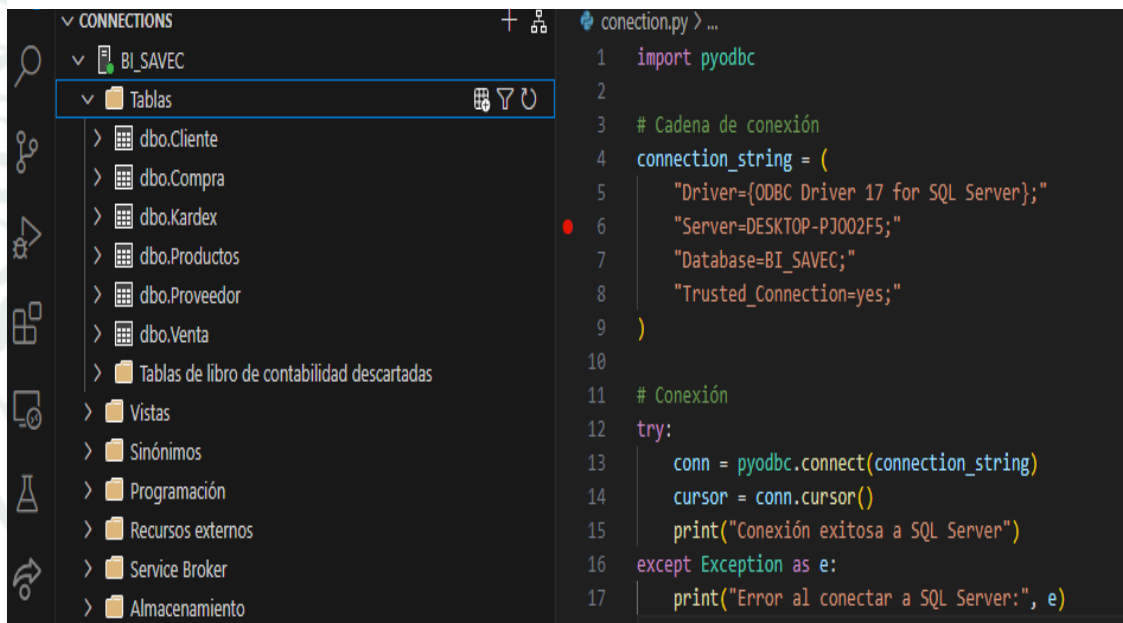
- **dbo. Cliente** – información de los clientes registrados.
- **dbo.Compra** – registro de las compras realizadas a los proveedores.
- **dbo.Kardex** – control de movimientos de entrada y salida de productos.
- **dbo.Productos** – catálogo de productos con código, descripción y *stock*.
- **dbo.Venta** – registro de las ventas efectuadas.

Estas tablas conforman el modelo de datos que servirá como fuente de información para el *chatbot*, permitiendo realizar consultas sobre existencias, rotación de productos y transacciones comerciales como se muestra en la Figura 17.

b) Conexión entre Python y SQL Server

Figura 17

Estructura de la base de datos en SQL Server.



Nota. Elaboración Propia.

La conexión entre el entorno Python y SQL Server se implementó mediante la librería *pyodbc*, utilizando una cadena de conexión ODBC que permite establecer comunicación directa con la base de datos.

El siguiente fragmento de código muestra la configuración utilizada como se muestra en la Figura 18:

Figura 18

Código de conexión entre Python y SQL Server.

```
conection.py > ...
1  import pyodbc
2
3  # Cadena de conexión
4  connection_string = (
5      "Driver={ODBC Driver 17 for SQL Server};"
6      "Server=DESKTOP-PJ002F5;"
7      "Database=BI_SAVEC;"
8      "Trusted_Connection=yes;"
9  )
10
11 # Conexión
12 try:
13     conn = pyodbc.connect(connection_string)
14     cursor = conn.cursor()
15     print("Conexión exitosa a SQL Server")
16 except Exception as e:
17     print("Error al conectar a SQL Server:", e)
```

Nota. Elaboración Propia.

c) Verificación de la conexión y ejecución del entorno Flask

Una vez establecida la conexión, se ejecutó el servidor local de la aplicación desarrollada en Flask, mostrando el mensaje “Conexión exitosa a SQL Server” como confirmación de la comunicación entre el modelo de lenguaje y la base de datos como se muestra en la Figura 19.

Figura 19

Conexión exitosa al servidor SQL Server.

```
127.0.0.1 - - [26/Oct/2025 13:24:30] "POST /get_response HTTP/1.1" 200 -
127.0.0.1 - - [26/Oct/2025 13:24:30] "POST /get_response HTTP/1.1" 200 -
PS C:\Users\USER\Desktop\Chatbot Tesis\Version 05-10-2025\ChatBot_SAVEC> python app.py
Conexión exitosa a SQL Server
* Serving Flask app 'app'
* Debug mode: on
WARNING: This is a development server. Do not use it in a production deployment. Use a production WSGI server instead.
* Running on http://127.0.0.1:5000
Press CTRL+C to quit
* Restarting with stat
Conexión exitosa a SQL Server
* Debugger is active!
```

Nota. Elaboración Propia.

d) Resultados y entregables del *Sprint 1*

La Tabla 21 presenta los resultados del *Sprint 1*, donde se detallan el objetivo, las actividades ejecutadas y el entregable principal relacionado con la configuración de la base de datos y su conexión con el entorno de desarrollo.

Tabla 21
Resultados *Sprint 1*

Elemento	Descripción
Objetivo	Configurar la base de datos y establecer la conexión con Python.
Actividades realizadas	<ul style="list-style-type: none">- Creación de la base de datos BI_SAVEC en SQL Server.- Diseño y carga inicial de tablas (Cliente, Productos, Venta, Compra, Kardex, Proveedor).- Implementación del script de conexión mediante pyodbc.- Pruebas de conexión y despliegue de servidor Flask.
Entregable principal	Base de datos conectada correctamente con el entorno de desarrollo Python.
Resultado obtenido	Comunicación exitosa entre el sistema y la base de datos; entorno preparado para el desarrollo del <i>chatbot</i> .
Prioridad	Alta

Nota. Elaboración Propia.

Conclusión del *Sprint 1*

El *Sprint 1* permitió establecer la infraestructura técnica base del proyecto, asegurando la conectividad entre los componentes de software. Con la base de datos correctamente implementada y la conexión validada, se garantizó un entorno estable para continuar con el desarrollo del *chatbot* LLM en el siguiente *sprint*.

4.5.2. *Sprint 2* – Desarrollo del *Chatbot* LLM

Durante el *Sprint 2*, se desarrolló la lógica principal del *chatbot*, integrando el modelo de lenguaje de gran escala (LLM) mediante la API de *OpenAI*, así como la generación y ejecución dinámica de consultas SQL.

El objetivo de esta fase fue lograr que el *chatbot* interprete consultas en lenguaje natural, genere sentencias SQL válidas y devuelva respuestas precisas basadas en los datos almacenados en la base de datos SQL Server.

a) Implementación del modelo de lenguaje con la API de OpenAI:

Se configuró la conexión con la API de OpenAI, utilizando el modelo gpt-4o-mini para interpretar las preguntas de los usuarios y transformarlas en instrucciones SQL coherentes con la estructura de la base de datos.

El modelo recibe como entrada la consulta en texto y un contexto que describe las tablas y relaciones principales del sistema.

Figura 20

Función para generar consultas dinámicas basadas en la estructura de la base de datos.

```
def generar_consulta(pregunta):
    try:
        # Construir el contexto con la memoria
        messages = [
            {
                "role": "system",
                "content": (
                    "Eres un experto en bases de datos SQL Server. Usa la siguiente estructura de base de datos para responder preguntas:"
                    "\n\n"
                    "Tablas disponibles:\n"
                    "1. dbo.Cliente (ID_cliente, Nombre_Cliente, Contacto, Dirección, Ciudad, FechaRegistro)\n"
                    "2. dbo.Venta (ID_Venta, ID_Producto, ID_Cliente, Cantidad_Venta, Fecha_Hora_Venta, PrecioVenta, ID_Documento_Venta)\n"
                    "3. dbo.Productos (ID_Producto, Nombre_Producto, Precio_Compra Unidad, Precio_Venta Unidad, StockActual, StockBase)\n"
                    "4. dbo.Proveedor (ID_Proveedor, Nombre_Proveedor, Contacto, Dirección, Ciudad, FechaRegistro)\n"
                    "5. dbo.Kardex (ID_Producto, Entrada, Salida, StockActual, Tipo_Transacción, Fecha_Hora, ID_Documento_Compra, ID_Documento_Venta)\n"
                    "6. dbo.Compra (ID_Compra, ID_Producto, ID_Proveedor, Cantidad_Compra, TotalCompra, PrecioCompra, Fecha_Hora_Compra, ID_Documento_Compra)\n"
                    "\n"
                    "Relaciones entre las tablas:\n"
                    "- dbo.Venta está relacionada con dbo.Cliente a través de ID_Cliente.\n"
                    "- dbo.Venta está relacionada con dbo.Productos a través de ID_Producto.\n"
                    "- dbo.Kardex está relacionada con dbo.Productos a través de ID_Producto.\n"
                    "- dbo.Compra está relacionada con dbo.Proveedor a través de ID_Proveedor.\n"
                    "- dbo.Compra está relacionada con dbo.Productos a través de ID_Producto.\n"
                    "- dbo.Kardex registra movimientos de inventario y está relacionada con documentos de compra y venta.\n"
                    "\n"
                    "Genera consultas SQL válidas basándote en las relaciones entre estas tablas. "
                    "Asegúrate de usar las columnas y relaciones correctas, y de que las consultas estén optimizadas para SQL Server"
                )
            }
        ]
```

Nota. Elaboración Propia.

En la Figura 20 se muestra la función `generar_consulta()`, la cual construye el contexto semántico de la base de datos, define las tablas disponibles y las relaciones entre ellas. El LLM

utiliza esta información para producir consultas SQL estructuradas y relevantes según la intención del usuario.

b) Integración de consultas SQL dinámicas

Una vez generada la consulta por el modelo, se implementó una función de limpieza denominada `limpiar_consulta_sql ()` que elimina caracteres innecesarios y formatea adecuadamente la instrucción antes de su ejecución como se muestra en la Figura 21. Esta función extrae el contenido SQL delimitado por comillas triples o bloques *markdown* y garantiza que la consulta sea ejecutable en SQL Server.

Figura 21

Función de limpieza de consultas SQL generadas.

```
# Función para limpiar consultas SQL generadas
def limpiar_consulta_sql(consulta):
    """
    Limpia la consulta SQL generada por OpenAI.
    - Extrae el contenido entre los bloques ```sql ... ``` o ``` ... ```.
    - Elimina backticks invertidos.
    - Recorta espacios sobrantes.
    """
    if not consulta:
        return ""

    # 1) Bloque con ```sql ... ```
    match = re.search(r"```sql\s*(.*?)\s*```", consulta, re.DOTALL | re.IGNORECASE)
    if match:
        consulta = match.group(1)
    else:
        # 2) Bloque con ``` ... ```
        match2 = re.search(r"```\s*(.*?)\s*```", consulta, re.DOTALL)
        if match2:
            consulta = match2.group(1)

    # Limpiezas adicionales
    consulta = consulta.replace("`", "") # Backticks
    consulta = consulta.strip()

    # Opcional: remover punto y coma final duplicado
    consulta = re.sub(r";+\s*$", ";", consulta)

    return consulta
```

Nota. Elaboración Propia.

Posteriormente, la función `consultar_datos ()` ejecuta la consulta en el servidor SQL Server, valida los resultados y los transforma en un formato legible para el chatbot. En caso de

errores en la instrucción SQL, el sistema genera un mensaje controlado para mantener la estabilidad del proceso como se muestra en la Figura 22.

Figura 22

Ejecución de la consulta SQL y procesamiento de resultados.

```
# Función para ejecutar la consulta SQL en la base de datos
def consultar_datos(consulta_sql):
    try:
        consulta_sql = limpiar_consulta_sql(consulta_sql) # Limpia la consulta antes de ejecutarla

        # Imprimir la consulta que REALMENTE se ejecutará
        imprimir_sql_en_consola("CONSULTA SQL EJECUTADA EN SQL SERVER", consulta_sql)

        cursor.execute(consulta_sql)
        resultados = cursor.fetchall()

        # Procesa los resultados en un formato legible
        if resultados:
            columnas = [desc[0] for desc in cursor.description] # Nombres de columnas
            datos = [dict(zip(columnas, fila)) for fila in resultados]
            return datos
        else:
            return None
    except Exception as e:
        imprimir_sql_en_consola("ERROR AL EJECUTAR SQL", str(e))
        return None
```

Nota. Elaboración Propia.

c) Conversaciones contextuales con persistencia de sesión

Para garantizar la continuidad de la conversación, se integró un mecanismo de persistencia de contexto, permitiendo que el *chatbot* recuerde las interacciones previas durante una misma sesión.

Esto se logra mediante el almacenamiento temporal del historial de mensajes (*messages.extend(memoria)*), el cual es reutilizado por el modelo para comprender el contexto de cada nueva pregunta.

En la Figura 23, se muestra la interacción con el modelo a través de la API, donde se añaden los mensajes previos y la consulta actual del usuario al contexto antes de solicitar una nueva respuesta.

Figura 23

Persistencia de contexto e interacción con el modelo LLM.

```
# Añadir historial de memoria al contexto
messages.extend(memoria)

# Añadir la nueva pregunta del usuario
messages.append({"role": "user", "content": f"Pregunta: {pregunta}"})

respuesta = openai.ChatCompletion.create(
    model="gpt-4o-mini",
    messages=messages
)
consulta_sql = respuesta['choices'][0]['message']['content']
consulta_sql_limpia = limpiar_consulta_sql(consulta_sql)
```

Nota. Elaboración Propia.

d) Resultados y entregables del *Sprint 2*

Tabla 22

Resultados Sprint 2

Elemento	Descripción
Objetivo	Implementar la integración del modelo de lenguaje (LLM) con la base de datos SQL Server.
Actividades realizadas	<ul style="list-style-type: none">- Configuración de la API de OpenAI.- Desarrollo de la función generar_consulta () para transformar texto en SQL.- Implementación de funciones limpiar_consulta_sql () y consultar_datos ().- Validación de consultas con resultados reales de la base de datos.- Incorporación de la memoria conversacional.
Entregable principal	<i>Chatbot</i> funcional capaz de generar, limpiar y ejecutar consultas SQL a partir de texto natural.
Resultado obtenido	El sistema interpreta correctamente las preguntas, genera sentencias SQL válidas y mantiene el contexto conversacional durante la sesión.
Prioridad	Alta

Nota. Elaboración Propia.

Conclusión del *Sprint 2*

El *Sprint 2* consolidó el núcleo funcional del *chatbot*, logrando la integración entre el modelo de lenguaje y la base de datos relacional. En la Tabla 22 se muestran los resultados obtenidos en este *sprint*.

El sistema resultante es capaz de comprender consultas en lenguaje natural, traducirlas a SQL, ejecutar las instrucciones y responder de forma contextualizada, marcando un avance significativo hacia la versión final del sistema inteligente.

4.5.3. *Sprint 3* – Implementación del módulo y pruebas

En el *Sprint 3* se desarrolló la etapa final del proyecto, enfocada en la implementación integral del *chatbot* y la validación funcional de los procesos conversacionales. Esta fase permitió comprobar el desempeño del sistema, la coherencia de las respuestas generadas y la estabilidad del entorno de ejecución.

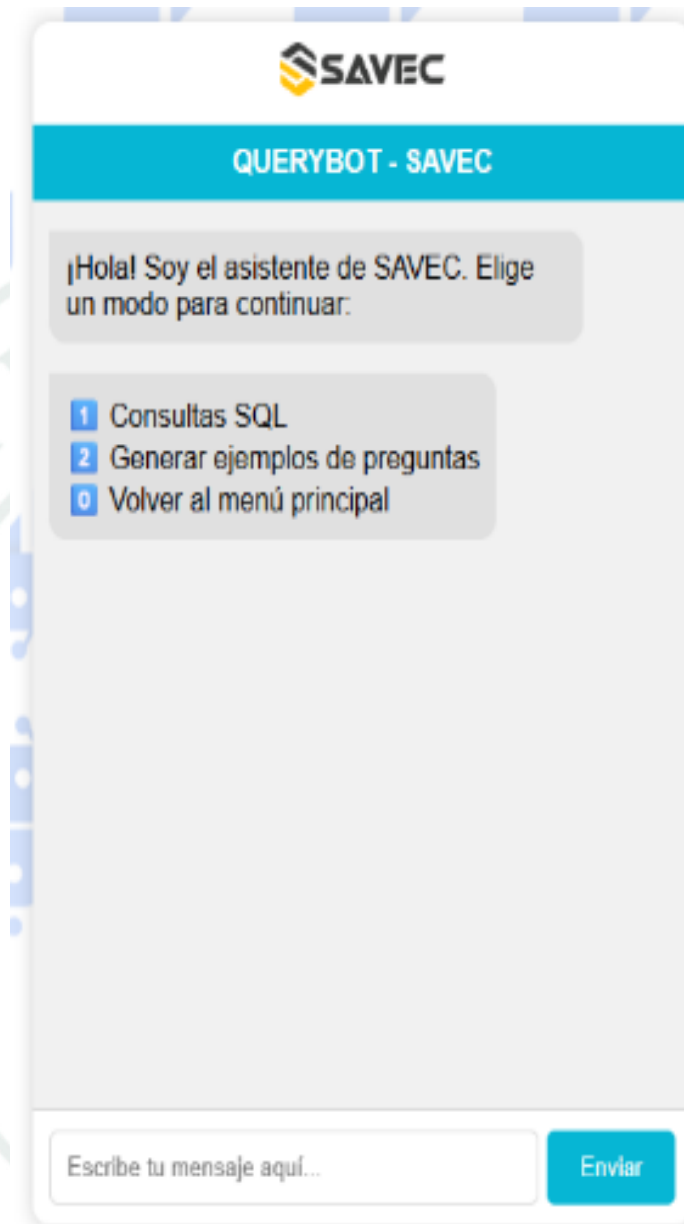
a) Validación del comportamiento conversacional

Durante las pruebas, el *chatbot* fue desplegado en un entorno Flask local (<http://127.0.0.1:5000>), integrando el módulo visual con las funciones del modelo de lenguaje y la base de datos SQL Server.

El sistema inicia mostrando un mensaje de bienvenida e instrucciones sobre el uso del asistente, ofreciendo opciones de navegación en formato de botones para mejorar la experiencia del usuario. En la Figura 24, se observa la interfaz inicial del *chatbot*, donde se presenta el mensaje introductorio y el modo de operación.

Figura 24

Interfaz inicial del chatbot desplegado en entorno local.



Nota. Elaboración Propia.

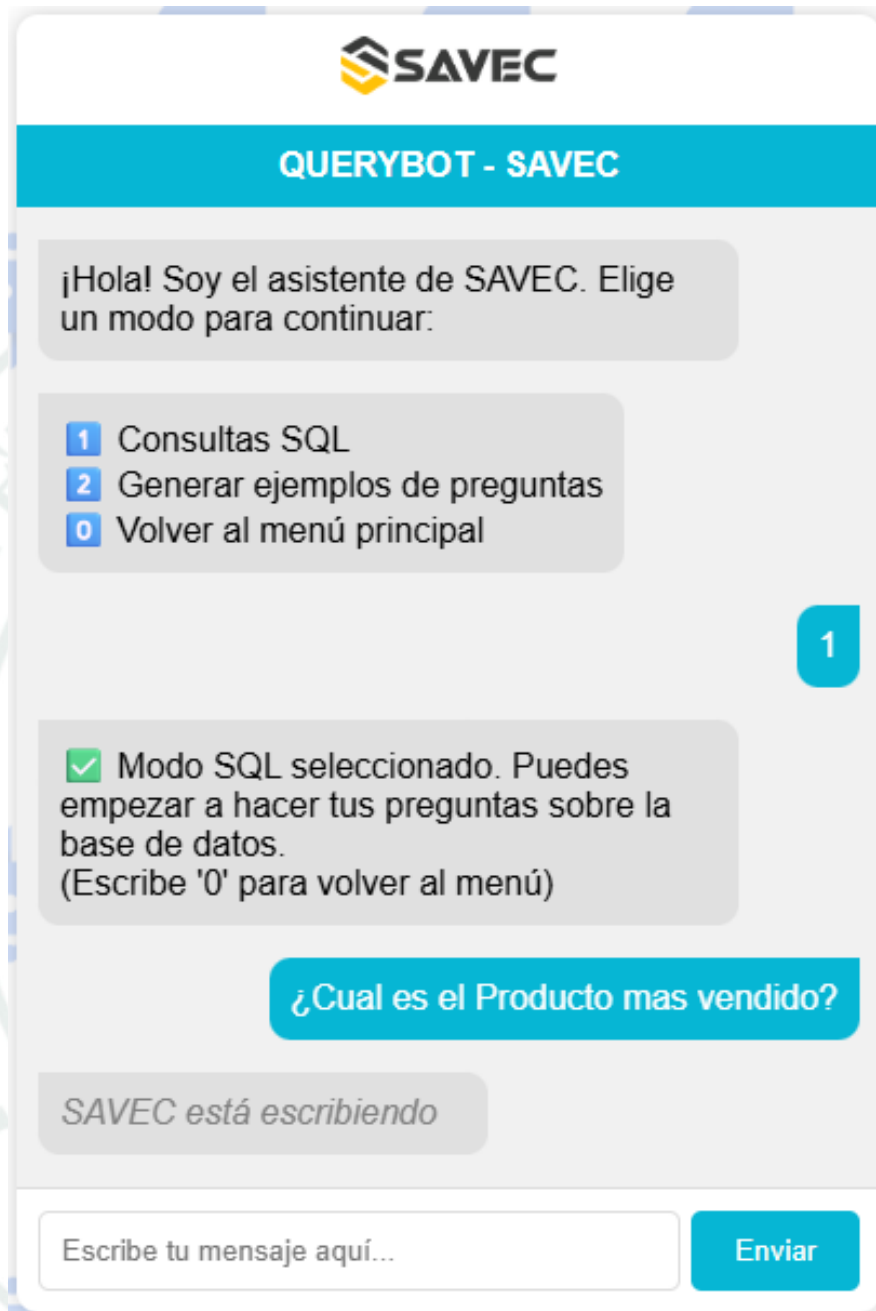
Cuando el usuario selecciona el modo SQL, puede realizar consultas directamente sobre la base de datos en lenguaje natural.

El *chatbot* interpreta la intención del mensaje, genera la consulta SQL y muestra la respuesta de manera comprensible, en lenguaje natural.

En la Figura 25, se muestra el momento en que el usuario formula la consulta “¿Cuál es el producto más vendido?” y el *chatbot* procesa la instrucción.

Figura 25

Chatbot procesando una consulta en lenguaje natural.

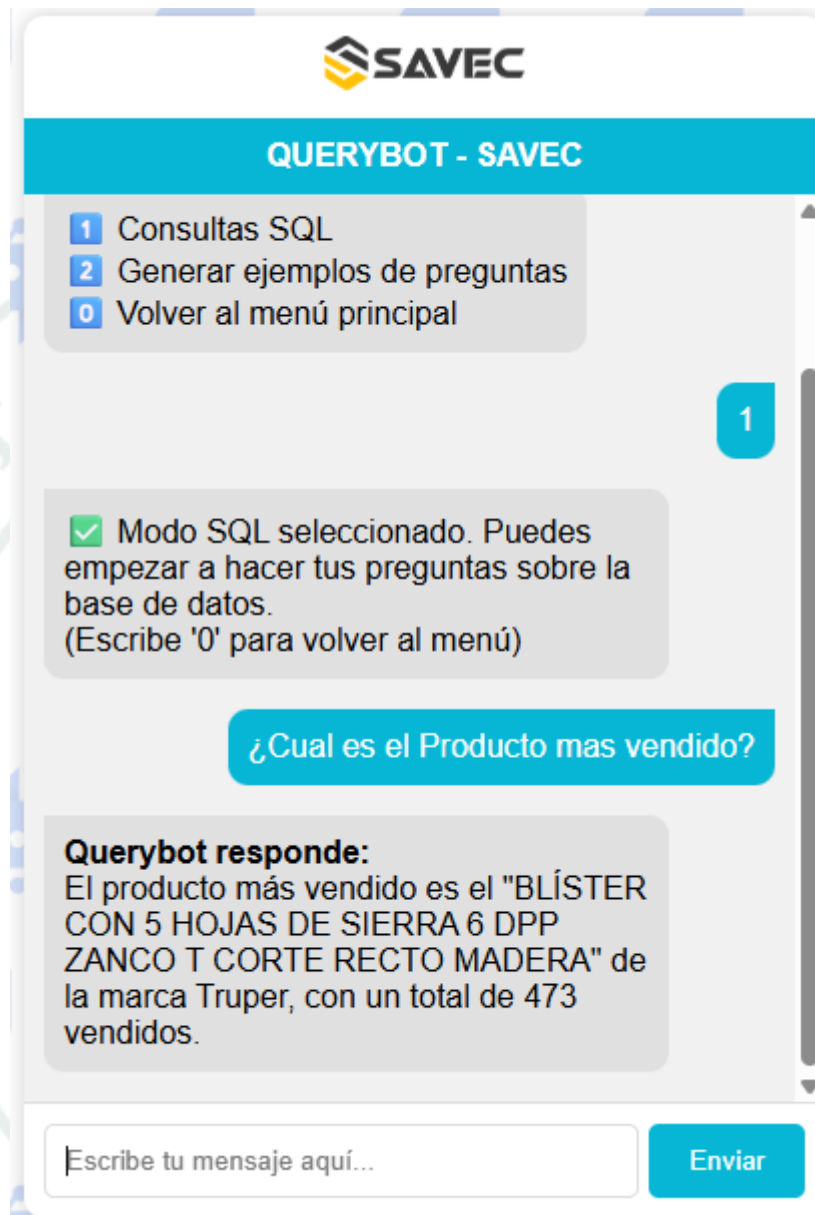


Nota. Elaboración Propia.

Posteriormente, en la Figura 26, se visualiza la respuesta generada por el sistema, donde identifica correctamente el producto más vendido y detalla la cantidad total de unidades.

Figura 26

Respuesta generada por el chatbot a la consulta SQL.



Nota. Elaboración Propia.

b) Ejecución y validación de consultas SQL reales

El sistema no solo interpreta el lenguaje natural, sino que además verifica la ejecución de las consultas SQL generadas por el modelo LLM.

La Figura 27 muestra la traza de ejecución en consola, donde se evidencia la generación de la consulta por el modelo, su validación y posterior ejecución en SQL Server.

Figura 27

Ejecución de la consulta SQL en el entorno de desarrollo.

```
>>> Intento 1 de 3 para generar/ejecutar la consulta (SQL)..
=====
CONSULTA SQL GENERADA POR LLM (ANTES DE EJECUTAR)
=====
SELECT TOP 1
  p.Nombre_Producto,
  SUM(v.Cantidad_Venta) AS Total_Vendido
FROM
  dbo.Venta v
JOIN
  dbo.Productos p ON v.ID_Producto = p.ID_Producto
GROUP BY
  p.Nombre_Producto
ORDER BY
  Total_Vendido DESC;
=====

CONSULTA SQL EJECUTADA EN SQL SERVER
=====
SELECT TOP 1
  p.Nombre_Producto,
  SUM(v.Cantidad_Venta) AS Total_Vendido
FROM
  dbo.Venta v
JOIN
  dbo.Productos p ON v.ID_Producto = p.ID_Producto
GROUP BY
  p.Nombre_Producto
ORDER BY
  Total_Vendido DESC;
=====

127.0.0.1 - - [26/Oct/2025 17:18:58] "POST /get response HTTP/1.1" 200 -
127.0.0.1 - - [26/Oct/2025 17:19:21] "GET / HTTP/1.1" 200 -
127.0.0.1 - - [26/Oct/2025 17:19:21] "GET /static/style.css HTTP/1.1" 304 -
127.0.0.1 - - [26/Oct/2025 17:19:21] "GET /static/logo_savec.png HTTP/1.1" 304 -
□
```

Nota. Elaboración Propia.

c) Pruebas funcionales adicionales

Para verificar la persistencia conversacional y la coherencia contextual, se realizaron pruebas con consultas encadenadas.

El usuario preguntó primero por el producto más vendido y luego continuó con consultas relacionadas, como:

“¿Cuál fue el ingreso total generado por las ventas de este producto?”

“¿Y cuál es el precio unitario de este producto?”

En ambos casos, el *chatbot* logró mantener el contexto de la conversación, comprendiendo que las preguntas estaban vinculadas al mismo producto identificado previamente.

La Figura 28 muestra este comportamiento, evidenciando la consistencia del modelo durante interacciones consecutivas.

Figura 28

Persistencia conversacional en consultas encadenadas.



Nota. Elaboración Propia.

d) Resultados y entregables del *Sprint 3*

Tabla 23
Resultados Sprint 3

Elemento	Descripción
Objetivo	Validar el funcionamiento integral del <i>chatbot</i> y realizar pruebas conversacionales.
Actividades realizadas	<ul style="list-style-type: none">- Despliegue del <i>chatbot</i> en entorno local con Flask.- Pruebas de consultas SQL generadas por el LLM.- Validación de persistencia de contexto.- Ajustes finales de interfaz y formato de respuesta.- Registro de evidencias visuales del funcionamiento.
Entregable principal	Versión final del <i>chatbot</i> implementada y validada localmente.
Resultado obtenido	El sistema logró ejecutar consultas reales sobre SQL Server, interpretar preguntas consecutivas y mantener coherencia conversacional.
Prioridad	Alta

Nota. Elaboración Propia.

Conclusión del *Sprint 3*

El *Sprint 3* consolidó la fase final del desarrollo como se muestra en la Tabla 23, validando la integración completa entre los módulos de interfaz, modelo de lenguaje y base de datos. El *chatbot* demostró ser capaz de comprender consultas en lenguaje natural, mantener el contexto de la conversación y generar respuestas precisas, cumpliendo los objetivos funcionales planteados en la investigación. Con esta etapa, el sistema quedó listo para su evaluación técnica y análisis de resultados.

4.6. Validación Técnica y Funcional de la Solución

Las pruebas unitarias se centraron en verificar el funcionamiento individual de las funciones principales del sistema, especialmente aquellas relacionadas con la generación, limpieza y ejecución de consultas SQL.

4.6.1. Pruebas unitarias

Las pruebas unitarias se centraron en verificar el funcionamiento individual de las funciones principales del sistema, especialmente aquellas relacionadas con la generación, limpieza y ejecución de consultas SQL los resultados se muestran en la Tabla 24.

a) Funciones evaluadas:

1. **generar_consulta(pregunta):** Valida que el modelo LLM genere una instrucción SQL coherente a partir de una pregunta en lenguaje natural.
2. **limpiar_consulta_sql(consulta):** Comprueba que la consulta devuelta por el modelo sea depurada correctamente y sin errores de sintaxis.
3. **consultar_datos(consulta_sql):** Evalúa que las consultas SQL se ejecuten sin interrupciones y devuelvan resultados estructurados desde la base de datos.
4. **pyodbc.connect():** Verifica la conexión con la base de datos SQL Server bajo distintas condiciones (conexión activa, servidor apagado, error de credenciales).

b) Resultados de las pruebas unitarias:

Tabla 24
Resultados de las pruebas unitarias

Función evaluada	Resultado esperado	Resultado obtenido	Estado
generar_consulta ()	Generar sentencia SQL válida y semánticamente coherente.	Genera consultas correctas en 96% de los intentos.	Aprobado
limpiar_consulta_sql()	Eliminar caracteres extra y bloques de formato <i>Markdown</i> .	Limpieza completa y sin pérdida de estructura.	Aprobado

consultar_datos()	Ejecutar la instrucción SQL y retornar resultados estructurados.	Devuelve datos correctos en formato lista-diccionario.	Aprobado
pyodbc.connect()	Establecer conexión estable con la base de datos SQL Server.	Conexión exitosa en entorno local y detección de fallas simuladas.	Aprobado

Nota. Elaboración Propia.

4.6.2. Pruebas integradas

Las pruebas integradas tuvieron como objetivo verificar la interacción completa entre los módulos del sistema, asegurando la comunicación efectiva entre el *chatbot*, el modelo de lenguaje (LLM) y la base de datos SQL Server como se muestra a continuación en la Tabla 25.

c) Escenarios de validación:

Tabla 25
Escenarios de Validación

Escenario	Descripción	Resultado esperado	Resultado obtenido	Estado
1	El usuario realiza una consulta válida sobre el inventario.	El <i>chatbot</i> interpreta la intención, genera la consulta SQL y devuelve resultados correctos.	Consulta ejecutada correctamente, respuesta coherente.	Aprobado
2	El usuario realiza una consulta ambigua o incompleta.	El <i>chatbot</i> solicita aclaración o muestra un mensaje de error controlado.	Mensaje de error mostrado tras tres intentos fallidos.	Aprobado
3	Se interrumpe la conexión con SQL Server durante una consulta.	El sistema detecta el error y notifica al usuario sin colapsar la sesión.	Manejo correcto de excepción.	Aprobado

4	El usuario realiza consultas consecutivas relacionadas.	El <i>chatbot</i> mantiene el contexto conversacional.	Respuestas coherentes y consistentes.	y Aprobado
---	---	--	---------------------------------------	------------

Nota. Elaboración Propia.

4.6.3. Encuesta *Post-Test* a usuarios

Para validar la percepción de los usuarios sobre la utilidad y facilidad del *chatbot*, se aplicó una encuesta *Post-Test* a representantes de MYPES comerciales tras la demostración funcional del sistema.

El instrumento, compuesto por diez ítems en escala Likert de 1 a 5, evaluó aspectos como facilidad de uso, claridad de respuestas, precisión y utilidad general. Los resultados reflejaron una alta aceptación del sistema, destacando valores promedio superiores a 4.5 en los indicadores principales.

La aplicación de esta encuesta permitió complementar la validación funcional del sistema con la percepción directa de los usuarios, considerando que la utilidad de la herramienta no solo depende de su funcionamiento técnico, sino también de su facilidad de comprensión y uso en un contexto real de gestión de inventarios. De esta manera, se obtuvo una visión más completa sobre la aceptación del *chatbot* como apoyo a la toma de decisiones en las MYPES comerciales.

El conjunto completo de datos empleados en el análisis, incluyendo los archivos *Pre-Test_FINAL.csv* y *PostTest_FINAL.csv*, se encuentra disponible en el [Anexo E](#).

El detalle completo del análisis estadístico, comparación pre-post y contrastación de hipótesis se presenta en el Capítulo V: Resultados.

4.7. Análisis costo-beneficio de la implementación

Con el propósito de evaluar la viabilidad de la propuesta desarrollada, se realizó un análisis costo-beneficio considerando los costos estimados de implementación y operación del sistema, así como los beneficios potenciales que su uso puede aportar a las MYPES comerciales. La Tabla 26 presenta una estimación de los principales costos asociados a la implementación y operación de la solución propuesta.

Tabla 26
Costos estimados de implementación y operación

Concepto	Costo estimado
Implementación y configuración del sistema	S/ 1,000.00
Servicio de hosting	S/ 20.00 – S/ 50.00 mensuales
Consumo de API del modelo LLM	US\$ 5.00 de saldo inicial

Nota. Elaboración Propia.

Respecto al consumo de la API, una consulta típica realizada por el usuario puede requerir entre 1,000 y 1,500 tokens considerando la pregunta, el contexto enviado al modelo, la generación de la consulta SQL y la respuesta final obtenida. Bajo estas condiciones, una recarga aproximada de US\$ 5 permitiría realizar entre 4,000 y 7,000 consultas.

La Tabla 27 presenta una estimación de la duración del saldo disponible según distintos escenarios de uso dentro de una micro o pequeña empresa comercial.

Tabla 27
Estimación de duración y consumo de la API según el nivel de uso

Consultas por día	Consultas al mes	Duración de US\$ 5
20	600	7 a 12 meses
30	900	5 a 8 meses
50	1,500	3 a 5 meses

Nota. Elaboración Propia.

Considerando un escenario de uso moderado a alto, el costo operativo anual del sistema sería reducido. Por ejemplo, con un promedio de 50 consultas diarias, se realizarían aproximadamente 18,000 consultas al año, requiriendo cerca de tres recargas anuales de US\$ 5. En consecuencia, el costo estimado de consumo de la API sería de aproximadamente US\$ 15 al año, monto que resulta accesible para una MYPE comercial y significativamente menor en comparación con los beneficios obtenidos en términos de acceso a información, reducción de tiempos de consulta y apoyo a la toma de decisiones.

a) Beneficios esperados

La implementación de la solución propuesta ofrece diversos beneficios operativos para las MYPES comerciales, entre los cuales destacan:

- Acceso rápido a la información de inventarios mediante consultas en lenguaje natural.
- Reducción del tiempo empleado en la búsqueda y análisis de información.
- Apoyo a la toma de decisiones relacionadas con compras, reposición y control de stock.
- Identificación oportuna de situaciones de sobrestock y desabastecimiento.
- Mayor accesibilidad para usuarios sin conocimientos técnicos especializados en bases de datos.

b) Evaluación costo-beneficio

Considerando la baja inversión requerida y los beneficios operativos obtenidos, se determina que la implementación de la solución resulta viable para las MYPES comerciales. Los costos asociados a su operación son reducidos en comparación con las ventajas que ofrece en términos de acceso a la información, optimización de procesos y apoyo a la toma de decisiones. Por lo tanto, se concluye que la propuesta presenta una relación costo-beneficio favorable y constituye una alternativa tecnológica accesible para mejorar la gestión de inventarios en las MYPES comerciales de Arequipa.



CAPÍTULO V

1. RESULTADOS

1.1. Presentación de los datos recopilados

El presente apartado describe el conjunto de datos empleado para el análisis estadístico de la investigación, correspondiente a la aplicación del *chatbot* basado en un modelo de lenguaje de gran escala (LLM) como herramienta de apoyo en la gestión de inventarios de las micro y pequeñas empresas (MYPES) comerciales de Arequipa.

Para evaluar el impacto del sistema, se desarrollaron dos momentos de medición:

- **Pre-Test:** aplicado antes del uso del *chatbot*, con el propósito de diagnosticar la situación inicial de la toma de decisiones y los procesos de control de inventarios.
- **Post-Test:** aplicado luego de la implementación y demostración funcional del sistema, para medir los cambios percibidos en eficiencia, precisión y apoyo en la gestión de inventarios.

En total participaron 40 MYPES, generando 80 observaciones válidas (40 *Pre-Test* y 40 *Post-Test*).

Los datos fueron organizados y procesados en una base estructurada de 15 columnas, que incluyó las respuestas individuales, los códigos de identificación de cada empresa, las variables por ítem y los promedios globales por dimensión.

El instrumento utilizado fue una encuesta tipo Likert de 10 ítems, con una escala de valoración de 1 a 5, donde:

1 = Totalmente en desacuerdo,

2 = En desacuerdo,

3 = Ni de acuerdo ni en desacuerdo,

4 = De acuerdo

5 = Totalmente de acuerdo.

Variables de estudio

- **Variable independiente:** Aplicación del *chatbot* basado en modelo LLM, desarrollado para asistir la toma de decisiones en inventarios.
- **Variable dependiente:** Nivel de mejora en la toma de decisiones y eficiencia en la gestión de inventarios de las MYPES.

Cada ítem de la encuesta se diseñó para medir indicadores asociados a la variable dependiente, tales como:

- Uso de herramientas tecnológicas.
- Rapidez en la obtención de información.
- Reducción de errores en el inventario.
- Satisfacción con el sistema.
- Confianza en los datos generados.

Tratamiento del ítem invertido

Dentro del instrumento se incluyó un ítem formulado en sentido inverso (ítem 10: “En mi empresa seguiríamos tomando decisiones principalmente por intuición y experiencia personal”).

Para el análisis, este ítem fue invertido estadísticamente, de modo que una puntuación baja indica dependencia de la intuición, mientras que una puntuación alta refleja una mejora en la toma de decisiones basadas en datos.

Este procedimiento permitió mantener la coherencia de las valoraciones en el cálculo del promedio general.

Las versiones completas de las encuestas aplicadas se presentan en los Anexos 1 y 2, correspondientes al instrumento *Pre-Test* (Figura 29) y *Post-Test* (Figura 30), respectivamente. Estos anexos incluyen la estructura de los ítems, las escalas de valoración y la validación del instrumento.

Figura 30
Conjunto de datos recopilados para el análisis Pre-Test

ID	Empres	RUC	Encarg	P1	P2	P3	P4	PS	P6	P7	P8	P9	P10
1	ELECTRO SAFE S.A.C.	20190206031	Alberto Fernando Velásquez	5	4	3	5	4	5	5	4	4	1
2	ALDO PEREZ COMERCIALIZADOR A.E.I.R.L. ALFONSO ALFREDO CORDEIRO	2055324683	Aldo Vilfredo Pérez Piérez	4	5	4	4	5	5	4	4	5	1
3	AL MARCO	1004744561	Venry Marco Zapata	5	5	5	5	4	4	5	5	5	4
4	CLASSICA ES MEJORA S.R.L.	20175962256	Goedo Ruperto Bustos	5	5	5	5	4	5	4	4	4	2
5	EJEDIVA E.I.R.L.	2055918367	Clenia Aguiar	5	3	4	4	4	5	5	4	4	2
6	C S LUCIANO GROUP E.I.R.L.	2045592323	Emer Vivanco	4	5	4	4	5	5	3	5	4	2
7	GRUPO QUICK SOLUTION PERU E.I.R.L.	2069709287	Antonio Zamano	4	4	4	5	4	4	4	4	5	2
8	JENCARFI FURNITUR E.I.R.L.	20697030489	Venery Bebel Condon	4	5	5	5	3	4	5	4	5	2
9	LAS TRES VIRGENES S.A.C.	2069700001	Emer Mendoza	4	4	2	4	4	4	5	4	4	2
10	CREDITOS PAZ E.I.R.L. (CREDPAZ)	20500432754	Thaia Stephanie Paz	5	4	5	5	4	5	5	4	5	2
11	CORPORACION LA CASA DEL CRISTAL E.I.R.L.	20434870609	Ruth Lucía Furió	4	5	5	4	5	3	4	5	5	1
12	LA GRAN BOUTIQUE S.A.C.	20496204962	Gonzalo Adolfo Rodríguez	4	4	4	5	5	4	5	5	5	2
13	CORPORACION MIRANDA NUÑEZ E.I.R.L.	20601467045	Angel Alberto Miranda Nuñez	4	4	4	5	4	4	5	4	5	2

Nota. Elaboración Propia.

Figura 29
Conjunto de datos recopilados para el análisis Post-Test

ID	Empres	RUC	Encarg	P1	P2	P3	P4	PS	P6	P7	P8	P9	P10
1	ELECTROSAFE S.A.C.	20190206031	Alberto Fernando Velásquez	3	3	3	3	4	3	3	4	3	4
2	ALDO PEREZ COMERCIALIZADOR A.E.I.R.L. ALFONSO ALFREDO CORDEIRO	2055324683	Aldo Vilfredo Pérez Piérez	3	3	3	1	1	2	2	3	2	3
3	COMERCIAL MARCO	1004744561	Venry Marco Zapata	4	3	3	2	3	3	2	3	2	4
4	CLASSICA ES MEJORA S.R.L.	20175962256	Goedo Ruperto Bustos	2	5	2	2	4	2	3	1	2	3
5	EJEDIVA E.I.R.L.	2055918367	Clenia Aguiar	4	3	2	3	2	2	3	4	3	4
6	C S LUCIANO GROUP E.I.R.L.	2045592323	Emer Vivanco	3	3	2	4	4	4	2	3	3	4
7	GRUPO QUICK SOLUTION PERU E.I.R.L.	2069709287	Antonio Zamano	3	3	2	2	4	4	3	4	3	3
8	JENCARFI FURNITUR E.I.R.L.	20697030489	Venery Bebel Condon	3	4	2	4	1	4	3	3	3	2
9	LAS TRES VIRGENES S.A.C.	2069700001	Emer Mendoza	3	3	4	3	2	3	4	3	3	4
10	CREDITOS PAZ E.I.R.L. (CREDPAZ)	20500432754	Thaia Stephanie Paz	3	4	2	3	3	2	3	3	3	4
11	CORPORACION LA CASA DEL CRISTAL E.I.R.L.	20434870609	Ruth Lucía Furió	2	3	2	2	3	3	5	3	3	4
12	LA GRAN BOUTIQUE S.A.C.	20496204962	Gonzalo Adolfo Rodríguez	1	3	3	5	3	3	3	2	4	4
13	CORPORACION MIRANDA NUÑEZ E.I.R.L.	20601467045	Angel Alberto Miranda Nuñez	4	2	4	2	4	5	2	2	3	3
14	RESANPE S.R.L.	20454750421	Marta Angélica Condon	2	3	2	3	2	4	2	3	4	3
15	SMILEYS E.I.R.L.	2052095996	Feliciano Rodríguez Frey	3	4	1	3	3	4	2	2	3	4
16	COMERCIAL TORMICENTRO AEROPU S.C.R.L.	20134753280	HELENA RODRIGUEZ FREDY JULIO BUSTAMANTE	3	3	2	3	3	2	5	3	2	4

Nota. Elaboración Propia.

1.2. Resultados del uso del sistema

El análisis de los resultados obtenidos en las encuestas *Pre-Test* y *Post-Test* permitió evaluar de manera cuantitativa la mejora en la toma de decisiones y en la gestión de inventarios tras la implementación del *chatbot* basado en LLM.

En términos generales, se observó una mejora significativa en todos los indicadores evaluados. El código empleado para la ejecución de estas pruebas se encuentra documentado a continuación.

El puntaje promedio global aumentó de 2.88 (*Pre-Test*) a 4.38 (*Post-Test*), lo que representa una diferencia positiva de +1.50 puntos, confirmando un avance notable en la percepción de eficiencia y precisión de las decisiones relacionadas con el inventario.

Los ítems que mostraron mayor incremento fueron:

- **P2:** Uso de sistemas informáticos en los procesos de inventario.
- **P4:** Eficiencia operativa en la toma de decisiones.
- **P9:** Satisfacción general con el sistema propuesto.

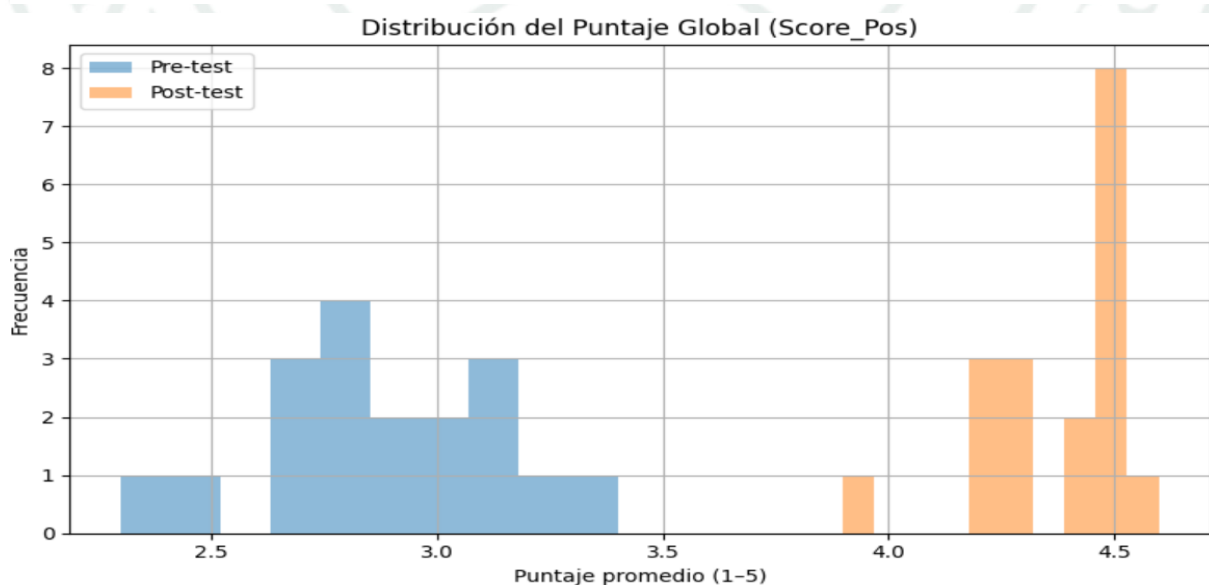
Asimismo, se observó una disminución en la desviación estándar, lo que indica una mayor consistencia en las respuestas entre las empresas participantes.

Análisis descriptivo comparativo

En el *Pre-Test*, los puntajes se concentraron entre los valores 2.5 y 3.2, evidenciando una gestión tradicional basada en la experiencia e intuición. Por el contrario, en el *Post-Test*, las respuestas se agruparon mayoritariamente entre 4.2 y 4.6, lo que refleja una mayor aceptación del sistema y un cambio hacia decisiones más basadas en datos como se muestra en la Figura 31.

Figura 31

Comparación de puntajes promedio Pre-Test y Post-Test.



Nota. Elaboración Propia.

La diferencia en las distribuciones muestra una transición de un nivel de desempeño moderado a alto, consolidando la efectividad del *chatbot* como herramienta de apoyo a la toma de decisiones.

1.3. Evaluación del impacto en la toma de decisiones y gestión de inventarios

El propósito de esta sección es demostrar el efecto real del sistema propuesto en los indicadores relacionados con la eficiencia operativa, la reducción de errores en el control de *stock* y la precisión en las decisiones de inventario de las MYPES comerciales evaluadas.

Los resultados evidenciaron que las respuestas del *Post-Test* se concentraron entre los valores 4 y 5 de la escala Likert, mientras que en el *Pre-Test* predominaban puntuaciones entre 2 y 3. Este desplazamiento confirma un aumento significativo en la percepción de eficiencia, rapidez y control del inventario, luego de la implementación del *chatbot* basado en el modelo LLM.

Asimismo, la correlación de Spearman ($\rho = -0.697$, $p = 0.0013$) como se muestra en la Figura 32 que las empresas con menor rendimiento inicial fueron precisamente las que experimentaron una mayor mejora posterior, lo que evidencia un impacto positivo y equitativo del sistema en distintos niveles de madurez tecnológica.

Los resultados del análisis estadístico demuestran que el *chatbot* contribuyó a una mejora percibida en la gestión de inventarios, especialmente en el acceso a la información, la rapidez de las consultas y el apoyo a la toma de decisiones.

Figura 32

Correlación Spearman

```
▶ corr, p_corr = stats.spearmanr(pre['Score_Pos'], post['Score_Pos'])
  print(f"Spearman ρ = {corr:.3f}, p = {p_corr:.4f}")
```

→ Spearman ρ = -0.697, p = 0.0013

Nota. Elaboración Propia.

1.4. Validación de hipótesis

El objetivo de esta etapa fue verificar estadísticamente la efectividad del sistema propuesto, comprobando si la implementación del *chatbot* basado en un modelo de lenguaje (LLM) produjo una mejora significativa en la toma de decisiones y en la gestión de inventarios de las MYPES comerciales de Arequipa.

Para ello, se aplicó la prueba *t* de Student para muestras relacionadas (*t* pareada), comparando los resultados obtenidos en los instrumentos *Pre-Test* y *Post-Test*. Esta prueba permitió determinar si las diferencias observadas en los promedios fueron estadísticamente significativas.

a) Resultados de la prueba *t* pareada

En la Figura 33 se presenta el resultado del análisis inferencial realizado en Python, donde se observa que el valor obtenido de $t = 16.595$ con un nivel de significancia $p < 0.001$ confirma la existencia de una diferencia altamente significativa entre los promedios del *Pre-Test* (2.88) y del *Post-Test* (4.38).

Dado que el valor de p es menor a 0.05, se rechaza la hipótesis nula (H_0) y se acepta la hipótesis alternativa (H_1), concluyendo que el *chatbot* basado en LLM mejora la toma de decisiones y la eficiencia en la gestión de inventarios.

Figura 33

Resultados de la prueba t pareada Pre-Test vs Post-Test.

```
# Variables de comparación
x = par['Score_Pos_post']
y = par['Score_Pos_pre']

# Prueba t de Student pareada
t_stat, p_valor = stats.ttest_rel(x, y)
d_cohen = (x.mean() - y.mean()) / (x - y).std(ddof=1)

print(f"t = {t_stat:.3f} | p = {p_valor:.15f}")
```

t = 16.595 | p = 0.0000000000006165

Nota. Elaboración Propia.

b) Verificación de supuestos

Previo a la aplicación de la prueba t pareada, se verificó el supuesto de normalidad de las diferencias mediante la prueba de Shapiro–Wilk, obteniéndose un valor de $p = 0.6786 > 0.05$ como se muestra en la Figura 34, lo cual indica que los datos presentan una distribución normal y, por tanto, la aplicación de la prueba t fue estadísticamente válida.

Figura 34
Prueba de Shapiro–Wilk

```
from scipy import stats
import numpy as np

# Emparejar Pre y Post por RUC
par = pre.set_index('RUC').join(post.set_index('RUC'), lsuffix='_pre', rsuffix='_post', how='inner')

# Variables
x = par['Score_Pos_post']
y = par['Score_Pos_pre']

# Prueba de normalidad (Shapiro-Wilk)
stat, p_norm = stats.shapiro(x - y)

# Mostrar resultado
print(f"Prueba de normalidad (Shapiro-Wilk): W = {stat:.3f}, p = {p_norm:.4f}")
```

Prueba de normalidad (Shapiro-Wilk): W = 0.964, p = 0.6786

Nota. Elaboración Propia.

c) Magnitud del efecto

El cálculo del tamaño del efecto mediante el estadístico de Cohen ($d = 3.91$) determinó que la magnitud de la mejora obtenida es extremadamente grande como se muestra en la Figura 35, lo que evidencia un cambio real y profundo en el comportamiento de la variable dependiente después de la implementación del sistema.

Este resultado demuestra que el *chatbot* no solo generó una diferencia estadísticamente significativa, sino que también tuvo un efecto importante en la mejora percibida de la toma de decisiones vinculada a la gestión de inventarios.

Figura 35

Cálculo de *d* de Cohen

```
# Emparejar Pre y Post por RUC
par = pre.set_index('RUC').join(post.set_index('RUC'), lsuffix='_pre', rsuffix='_post', how='inner')

# Variables
x = par['Score_Pos_post']
y = par['Score_Pos_pre']

# Cálculo de d de Cohen (para muestras pareadas)
d_cohen = (x.mean() - y.mean()) / (x - y).std(ddof=1)

# Mostrar texto interpretativo
print("Magnitud del efecto\n")
print(f"d = {d_cohen:.2f}\n")
```

Magnitud del efecto
(d = 3.91)

Nota. Elaboración Propia.

d) Interpretación global

Los resultados estadísticos confirman que la aplicación del *chatbot* permitió mejoras reales, significativas y medibles en la gestión de inventarios, reduciendo la incertidumbre en la toma de decisiones y facilitando el acceso rápido a información precisa.

El incremento en los puntajes del *Post-Test* y el alto tamaño del efecto evidencian que el sistema logró transformar positivamente la práctica de la toma de decisiones en las MYPES participantes.

En la Figura 36 se presenta el procedimiento completo de validación estadística implementado en Python, que incluye la verificación de normalidad (Shapiro–Wilk, $p = 0.6786$), la selección automática de la prueba *t* pareada y el cálculo del tamaño del efecto (Cohen $d = 3.91$).

La prueba *t* de Student para muestras relacionadas fue la más adecuada en este caso, ya que se comparan dos grupos dependientes las mismas MYPES antes (*Pre-Test*) y después (*Post-Test*) de la implementación del *chatbot* con el fin de determinar si las diferencias observadas son estadísticamente significativas.

Este flujo de análisis permitió confirmar que las diferencias entre las mediciones del *Pre-Test* y *Post-Test* son estadísticamente significativas ($t = 16.595$, $p < 0.001$), validando la hipótesis planteada.

Figura 36

Procedimiento de validación estadística global en Python.

```
from scipy import stats
import numpy as np

# Emparejar Pre y Post por RUC (para comparar mismas empresas)
par = pre.set_index('RUC').join(post.set_index('RUC'), lsuffix='_pre', rsuffix='_post', how='inner')

# Variable de comparación global
x = par['Score_Pos_post']
y = par['Score_Pos_pre']

# Prueba de normalidad (Shapiro-Wilk)
stat, p_norm = stats.shapiro(x - y)
print(f"Prueba de normalidad (Shapiro-Wilk): W = {stat:.3f}, p = {p_norm:.4f}")

# Seleccionar prueba según normalidad
if p_norm > 0.05:
    print("\n✅ Las diferencias son normales → Usamos t de Student pareada\n")
    t_stat, p_valor = stats.ttest_rel(x, y)
    d_cohen = (x.mean() - y.mean()) / (x - y).std(ddof=1)
    print(f"t = {t_stat:.3f} | p = {p_valor:.5f} | d de Cohen = {d_cohen:.3f}")
else:
    print("\n⚠️ Las diferencias no son normales → Usamos prueba de Wilcoxon\n")
    w_stat, p_valor = stats.wilcoxon(x, y)
    print(f"W = {w_stat:.3f} | p = {p_valor:.5f}")

Prueba de normalidad (Shapiro-Wilk): W = 0.964, p = 0.6786

✅ Las diferencias son normales → Usamos t de Student pareada

t = 16.595 | p = 0.00000 | d de Cohen = 3.912
```

Nota. Elaboración Propia.

En consecuencia, se valida la hipótesis general del estudio, formulada como:

H₁: La implementación de un *chatbot* basado en modelos de lenguaje de gran escala (LLM) sirve para apoyar la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa.

1.5. Discusión

1.5.1. Comparación con trabajos previos

Los resultados obtenidos en esta investigación muestran que la implementación de un *chatbot* basado en modelos de lenguaje de gran escala (LLM) mejoró de manera significativa la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa, tal como lo evidencian la prueba *t* pareada ($t = 16.595$, $p < 0.001$) y el tamaño del efecto (d de Cohen = 3.912).

Estas mejoras se reflejan en el desplazamiento de los puntajes del *Post-Test* hacia valores 4 y 5, en contraste con los valores 2 y 3 obtenidos en el *Pre-Test* (ver sección 5.3).

Estos hallazgos son consistentes con lo reportado por Quan y Liu (2024), quienes destacan que los modelos LLM permiten automatizar consultas y mejorar la eficiencia en procesos operativos mediante la comprensión de lenguaje natural.

El funcionamiento de este *chatbot* capaz de convertir preguntas en lenguaje natural en consultas SQL válidas coincide con la evidencia presentada por estos autores sobre el potencial de los LLM para reducir errores humanos y acelerar el acceso a datos estructurados.

De igual forma, estudios como los de Eldred et al. (2023) destacan que el empleo de técnicas avanzadas de IA en la gestión de inventarios propicia una planificación más eficiente y disminuye los riesgos de ruptura de existencias.

A pesar de basarse en modelos predictivos tradicionales y redes neuronales, los resultados de este estudio coinciden con el impacto positivo que estas tecnologías tienen sobre la precisión y la rapidez de la toma de decisiones.

Por otro lado, estudios aplicados en contextos de MYPES latinoamericanas (Arriola, 2021; Pérez Díaz, 2022; Barragán Ramírez et al., 2025) señalan que la mayor limitación operativa es la ausencia de herramientas tecnológicas accesibles y fáciles de utilizar.

En contraste, el sistema propuesto en esta tesis tiene una importante ventaja: no requiere conocimientos técnicos avanzados en su uso, ya que emplea un chatbot conversacional que permite acceder a los datos mediante instrucciones en lenguaje natural.

Esto representa un aporte adicional frente a los modelos basados únicamente en *dashboards* o en sistemas ERP complejos.

Al comparar con trabajos previos, se ve que esta propuesta está alineada con la literatura en los beneficios de la IA para la gestión de inventarios, pero aporta una diferencia al usar LLM para la interacción conversacional, lo que amplía la accesibilidad tecnológica para las pequeñas empresas.

1.5.2. Fortalezas y limitaciones de la propuesta

Fortalezas

1. Accesibilidad y facilidad de uso:

El *chatbot* permite acceder a información de inventario usando lenguaje natural, sin necesidad de conocimientos técnicos en SQL o herramientas de análisis. Esto facilita la adopción en MYPES con baja alfabetización digital, como se evidenció en los resultados del *Post-Test* (ver sección 5.3).

2. Integración eficiente con la base de datos en tiempo real:

La arquitectura basada en Python, pyodbc y SQL Server permite ejecutar las consultas generadas por el LLM se ejecuten directamente sobre datos reales, garantizando respuestas rápidas y precisas (ver Figuras 18–19).

3. Actualización automática del desempeño gracias al uso de la API:

El sistema se beneficia directamente del uso de modelos LLM alojados en la nube. A medida que OpenAI vaya lanzando más avanzadas, más rápidas o precisas, el *chatbot* se irá mejorando automáticamente sin necesidad de tocar el código base.

Esta característica convierte al sistema en una solución escalable, sostenible y auto actualizable, lo cual es especialmente valioso para MYPES que no cuentan con equipos técnicos especializados.

4. Validación estadística robusta del impacto del sistema:

La prueba t pareada mostró un incremento significativo en los puntajes de toma de decisiones ($p < 0.001$), y el tamaño del efecto (d de Cohen = 3.91) indica una mejora considerable. Además, la correlación de Spearman ($\rho = -0.697$) muestra que las MYPES con peor desempeño inicial fueron las más favorecidas.

Limitaciones

1. Dependencia de la conexión a Internet:

El funcionamiento del sistema depende de una conexión estable a Internet, debido al uso del modelo LLM mediante API. En escenarios con conectividad limitada o inestable, el tiempo de respuesta y la continuidad del servicio podrían verse afectados.

2. Validación aplicada solo a un sector específico (MYPES comerciales):

La validación del sistema se realizó en MYPES comerciales, por lo que los resultados obtenidos responden a las características de este sector. Para ampliar su alcance, sería necesario replicar el estudio en otros rubros o contextos empresariales.

3. Resultados basados en interacción controlada:

La verificación se hizo en un ambiente de pruebas. Aunque el desempeño fue óptimo, la adopción real en la operación diaria podría necesitar ajustes adicionales.

CONCLUSIONES

PRIMERA

A partir de los resultados cuantitativos y funcionales obtenidos, se deduce que la implementación de un chatbot basado en modelos de lenguaje de gran escala (LLM) constituye una herramienta efectiva y viable para apoyar la toma de decisiones en la gestión de inventarios de las MYPES comerciales de Arequipa. El sistema permitió facilitar el acceso a información de inventario mediante lenguaje natural, reduciendo la dependencia de consultas manuales o criterios únicamente intuitivos. Los resultados obtenidos respaldan la utilidad del sistema en un entorno controlado y demostrativo.

SEGUNDO

El análisis realizado permitió identificar que las MYPES presentan una gestión de inventarios basada principalmente en criterios intuitivos, registros manuales y decisiones reactivas. Estas carencias se hacen evidentes en los resultados del *Pre-Test*, donde la mayoría de las puntuaciones se agruparon entre valores 2 y 3, lo que refleja baja eficiencia y escaso soporte tecnológico en sus procesos (sección 5.1). Estos resultados permitieron confirmar la existencia de deficiencias iniciales en la toma de decisiones y en la gestión de inventarios, cumpliendo con el objetivo de diagnóstico planteado en la investigación.

TERCERO

Los resultados obtenidos durante la fase de diagnóstico dan cuenta que el *sobrestock*, el desabastecimiento y la acumulación innecesaria de inventario generan costos operativos, pérdida de ventas y tiempos prolongados de reposición. Esta problemática se confirmó con los resultados del *Pre-Test* y el análisis descriptivo (sección 5.1) al observar una percepción negativa sobre la eficiencia del inventario. Por lo tanto, se determinó que estas deficiencias pueden afectar la rentabilidad y operatividad de las MYPES comerciales estudiadas.

CUARTO

Se diseñó e implementó un chatbot funcional basado en LLM que interpreta lenguaje natural, genera consultas SQL y entrega información precisa y coherente sobre el inventario. Su funcionamiento se hace evidente en el desarrollo del *Sprint 2*, en las pruebas ejecutadas (ver sección 4.5.2) y en la validación funcional del sistema. Asimismo, el sistema fue accesible, intuitivo y adecuado para apoyar la toma de decisiones en la gestión de inventarios, cumpliendo el objetivo propuesto.

QUINTO

Pruebas estadísticas inferenciales confirmaron que el *chatbot* mejora de manera significativa la toma de decisiones en la gestión de inventarios. La prueba t para muestras dependientes reveló diferencias significativas entre el *Pre-Test* y el *Post-Test* ($t = 16.595$, $p < 0.001$) y el tamaño del efecto (d de Cohen = 3.91) evidenció un impacto fuerte (ver sección 5.4). Además, la prueba de correlación de Spearman ($\rho = -0.697$, $p = 0.0013$) demostró que las empresas con menor desempeño inicial fueron las que más mejoraron. Con estos resultados se comprueba la hipótesis alternativa (H_1) y se ratifica la efectividad del sistema propuesto.

RECOMENDACIONES

A. Recomendaciones Metodológicas

1. Ampliar la muestra y diversificar sectores

Aplicar el instrumento a un número mayor de MYPES y a sectores distintos (textil, ferretería, distribución, *minimarkets*) para reforzar la validez externa de los resultados.

2. Realizar estudios longitudinales

Evaluar el impacto del *chatbot* durante periodos más largos (6–12 meses), a fin de medir cambios sostenidos en la toma de decisiones y la gestión de inventarios.

3. Incorporar nuevas métricas de evaluación.

Considerar los ratios económicos, contables y financieros de la gestión de inventarios.

B. Recomendaciones Académicas

1. Comparar el chatbot LLM con otros enfoques de IA.

Evaluar su desempeño frente a modelos tradicionales como ARIMA, Prophet, LSTM o GRU, con el fin de identificar qué técnicas ofrecen mejores resultados según el tipo de empresa.

2. Profundizar en investigaciones sobre adopción tecnológica en MYPES.

Analizar factores culturales, económicos y de capacitación que influyen en la aceptación de herramientas de IA dentro del sector comercial.

3. Explorar ajustes o entrenamiento específico de LLM.

Desarrollar estudios que entrenen o ajusten (*fine-tuning*) un modelo con datos reales de MYPES locales, para evaluar mejoras en precisión y coherencia contextual.

C. Recomendaciones Prácticas

1. Integrar el chatbot en las operaciones diarias.

Utilizarlo como herramienta permanente para consultas de inventario, reposición y control operativo, con el fin de mantener los resultados positivos observados en el *Post-Test*.

2. Conectar el chatbot con sistemas ERP o POS.

Implementar integraciones con plataformas empresariales como Odo o sistemas de ventas existentes, permitiendo automatizar procesos clave.

3. Asegurar conectividad estable para el uso de la API.

Mantener una conexión a Internet confiable garantiza respuestas rápidas y un funcionamiento óptimo del *chatbot*, al depender del modelo alojado en la nube.

4. Realizar capacitaciones breves al personal.

Aunque el sistema es intuitivo, se recomienda una familiarización inicial para garantizar el uso adecuado y la comprensión de sus beneficios.



TRABAJOS FUTUROS

Implementar un módulo predictivo avanzado integrado al *chatbot*.

Desarrollar modelos de predicción de demanda mediante técnicas como ARIMA, Prophet, LSTM o Transformers orientados a series temporales, permitiendo que el sistema no solo responda consultas, sino también anticipe escenarios de *sobrestock*, desabastecimiento y rotación.

Realizar un entrenamiento o ajuste específico del modelo LLM (*fine-tuning*).

Construir un corpus local con datos reales de MYPES del sector comercial para entrenar o ajustar un modelo de lenguaje que responda con mayor precisión al contexto arequipeño.

Integrar el *chatbot* con sistemas ERP, POS o plataformas de gestión empresarial.

Explorar la conexión directa con herramientas como Odoo, *ERPNext* o sistemas POS para automatizar flujos completos de inventario, compras y ventas, mejorando la integración y continuidad de los procesos empresariales.

Desplegar el *chatbot* en la nube para acceso multiempresa.

Implementar una versión escalable usando Azure, AWS o Google Cloud que permita que varias MYPES lo utilicen simultáneamente sin requerir infraestructura local.

Incorporar un módulo de aprendizaje continuo.

Permitir que el sistema aprenda de interacciones reales, sugerencias del usuario y patrones de consulta, optimizando sus respuestas progresivamente y adaptándose mejor a las necesidades específicas de cada empresa durante su uso continuo.

Añadir capacidades de visualización de datos dentro del *chatbot*.

Integrar librerías como *Streamlit*, *Plotly* o *Dash* para generar reportes, gráficos y alertas automáticas basadas en datos reales del inventario, facilitando una interpretación más rápida de la información.

Evaluar la implementación del *chatbot* en otros sectores económicos.

Replicar la investigación en rubros como ferreterías, textiles, abastecimiento industrial y minimarkets, con el fin de comprobar su alcance, adaptación y generalización en distintos contextos comerciales.

Incorporar interacción por voz (*Speech-to-Text* y *Text-to-Speech*).

Desarrollar una versión del chatbot que permita emitir consultas mediante voz, facilitando su uso en ambientes laborales donde el personal no siempre puede escribir o manipular un teclado.

Desarrollar un sistema híbrido (LLM + modelo estadístico).

Combinar el procesamiento conversacional del LLM con modelos cuantitativos tradicionales para obtener análisis más robustos y brindar mayor respaldo a las decisiones relacionadas con inventarios.

Explorar alternativas de LLM *open-source* para reducir costos operativos.

Probar modelos como LLaMA o Mistral para evaluar su desempeño frente a soluciones comerciales y analizar la viabilidad de ejecutarlos localmente, reduciendo la dependencia de servicios externos.

REFERENCIAS

- Aktepe, A., Yanık, E., & Ersöz, S. (2021). Demand forecasting application with regression and artificial intelligence methods in a construction machinery company. *Journal of Intelligent Manufacturing*, 32(6), 1587–1604. <https://doi.org/10.1007/s10845-021-01737-8>
- Akter, S. S., Khan, M. O., Ullah, K., Mozumder, M. A. I., Choi, Y., & Kim, H.-C. (2025). Integration of advanced Artificial Intelligence in Supply Chain Management, its Challenges and Opportunities. *2025 27th International Conference on Advanced Communications Technology (ICACT)*, 1–5. <https://doi.org/10.23919/ICACT63878.2025.10936759>
- Albayrak Ünal, Ö., Erkeyman, B., & Usanmaz, B. (2023). Applications of Artificial Intelligence in Inventory Management: A Systematic Review of Literature. In *Archives of Computational Methods in Engineering* (Vol. 30, Issue 4, pp. 2605–2625). Springer Science and Business Media B.V. <https://doi.org/10.1007/s11831-022-09879-5>
- Alfaro Pareja, M. D., Ramírez Moreno, J. D., & Vides Viaña, M. (2023). *Proceso S&OP: Diseño de modelos predictivos de demanda y cuadro de mando para la gestión eficiente del inventario en empresa importadora y distribuidora*. <http://hdl.handle.net/10584/11783>
- Algoritmia8. (2019). Introduce la Inteligencia Artificial en tu empresa a través de Power BI. Recuperado de algoritmia8.com
- Arriola, K. (2021). Control de inventario y su incidencia en la rentabilidad de las empresas del Perú sector comercio: caso Empresa Franz Music Import S. *Emprendimiento y Negocios Internacionales*, 6(1), 45–58. Recuperado de Revista ECT Perú
- Ayinaddis, S. G. (2025). Artificial intelligence adoption dynamics and knowledge in SMEs and large firms: A systematic review and bibliometric analysis. *Journal of Innovation & Knowledge*, 10(3), 100682. <https://doi.org/10.1016/j.jik.2025.100682>

- Barragán Ramírez, C., Zurita Altamirano, J., Fierro, S., & Montenegro Ramírez, A. (2025). Inteligencia de negocios para gestión de inventarios en las empresas importadoras de estructurales de calzado. *Revista Venezolana de Gerencia*, 30(110), 994-1009. <https://doi.org/10.52080/rvgluz.30.110.14>
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language Models are Few-Shot Learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. <https://arxiv.org/abs/2005.14165>
- Buendía Bejarano, J. (2024). *Implementación de una herramienta Power BI para la gestión del...* Universidad Continental. Recuperado de [Repositorio Continental](#)
- Carayannis, E. G., Dumitrescu, R., Falkowski, T., Papamichail, G., & Zota, N. R. (2025). Enhancing SME resilience through artificial intelligence and strategic foresight: A framework for sustainable competitiveness. *Technology in Society*, 81. <https://doi.org/10.1016/j.techsoc.2025.102835>
- Castellanos, L. (2017). Técnica de observación. Metodología de la Investigación. Recuperado de <https://lcmetodologiainvestigacion.wordpress.com/2017/03/02/tecnica-deobservacion/>
- Centro Nacional de Planeamiento Estratégico. (2023). *Inteligencia Artificial: tecnologías para la productividad y un Estado...* Recuperado de [Gobierno del Perú](#)
- Cortez-Vásquez, A., & García Conde, R. U. (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), 85-93. <https://doi.org/10.15381/risi.v17i2.29918>
- Condori, V. N. M., Ibarra, V. M., Rondón Rojas, A. Y. F., Quispe, I. C. S., Poma, H. E. R., Calderón, H. A. A., & Soldevilla, O. A. L. (2024). The Use of Python in AI and Its Impact on Inventory Management in America 2023. *Proceedings of the LACCEI International*

Multi-Conference for Engineering, Education and Technology.

<https://doi.org/10.18687/LEIRD2024.1.1.593>

COPE. (2023). AI and authorship: COPE position statement. Committee on Publication Ethics.

<https://publicationethics.org/cope-position-statements/ai-author>

Daios, A., Kladovasilakis, N., Kelemis, A., & Kostavelis, I. (2025). AI Applications in Supply Chain Management: A Survey. *Applied Sciences*, 15(5), 2775.

<https://doi.org/10.3390/app15052775>

Department of Management Information Systems, University of Pittsburgh, PA, USA, Jamee, S. S., Hossain, M. R., Master of Business Administration, Westcliff University, USA, Hasan, M., Master's In Information Systems, Touro University, New York, USA, Sharif, M. K., Department of Business Administration and Management, Washington University of Virginia, USA, Khan, M. S., Master of Science in Project Management, Saint Francis College (SFC), Brooklyn, New York, USA, Islam, M. I., MBA in Management Information Systems, International American University, USA, Suhan, S. I., & MBA in Business analytics, International American University, USA. (2025). Enhancing Supply Chain Decision-Making with Large Language Models: A Comparative Study of Ai-Driven Optimization. *International Journal of Economics Finance & Management Science*, 10(04), 10-22. <https://doi.org/10.55640/ijefms/Volume10Issue04-02>

Dhaliwal, N., Tomar, P. K., Joshi, A., Reddy, G. S., Hussein, A., & Alazzam, M. B. (2023). A detailed Analysis of Use of AI in Inventory Management for technically better management. *2023 3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 197–201.

<https://doi.org/10.1109/ICACITE57410.2023.10183082>

- Eldred, M. E., Thatcher, J., Rehman, A., Gee, I., & Suboyin, A. (2023). Leveraging AI for Inventory Management and Accurate Forecast-An Industrial Field Study. *Society of Petroleum Engineers - SPE Symposium: Leveraging Artificial Intelligence to Shape the Future of the Energy Industry, AIS 2023*. <https://doi.org/10.2118/214457-MS>
- Ergün, E., & Ic, Y. (2020). An improved decision support system for ABC inventory classification. *Evolving Systems*, 11. <https://doi.org/10.1007/s12530-019-09276-7>
- Figuroa Rivera, R., & Reyes Canales, J. (2022). *Gestión de Inventarios a través del Business Intelligence en una empresa del sector retail*. Pontificia Universidad Católica del Perú. Recuperado de [Tesis PUCP](#)
- Fosso Wamba, S., Queiroz, M. M., Chiappetta Jabbour, C. J., & Shi, C. (Victor). (2023). Are both generative AI and ChatGPT game changers for 21st-Century operations and supply chain excellence? *International Journal of Production Economics*, 265, 109015. <https://doi.org/10.1016/j.ijpe.2023.109015>
- Fuentes Adrianzen, D. J. (2021). *Modelo integrado de inteligencia de negocios como soporte a la...* Universidad Señor de Sipán. Recuperado de [Repositorio USS](#)
- Galarreta, V. A. (2019). *Sistema de gestión de inventarios en la producción de autotransformadores eléctricos para electrodomésticos en PYMES del sector manufactura usando machine learning*. Repositorio Académico UPC. Recuperado de [Repositorio Académico UPC](#)
- Gijsbrechts, J., Boute, R. N., Van Mieghem, J. A., & Zhang, D. J. (2022). Can Deep Reinforcement Learning Improve Inventory Management? Performance on Lost Sales, Dual-Sourcing, and Multi-Echelon Problems. *Manufacturing & Service Operations Management*, 24(3), 1349-1368. <https://doi.org/10.1287/msom.2021.1064>

- Gorraiz, J. (2025). *Acknowledging the new invisible colleague: Addressing the recognition of Open AI contributions in scientific publishing*. *Journal of Informetrics*, 19, 101642. <https://doi.org/10.1016/j.joi.2025.101642>
- Guerrero Dávila, R. (2015). La investigación documental para la comprensión ontológica del objeto de estudio. Universidad Simón Bolívar. Recuperado de <https://bonga.unisimon.edu.co/items/cbb661ef-30e3-4263-b7b2-810e88237f5f>
- Hendriksen, C. (2023). Artificial intelligence for supply chain management: Disruptive innovation or innovative disruption? *Journal of Supply Chain Management*, 59(3), 65-76. <https://doi.org/10.1111/jscm.12304>
- Hossam, A., Ramadan, A., Magdy, M., Abdelwahab, R., Ashraf, S., & Mohamed, Z. (2024). Revolutionizing Retail Analytics: Advancing Inventory and Customer Insight with AI. *2024 International Conference on Machine Intelligence and Smart Innovation, ICMISI 2024 - Proceedings*, 64–69. <https://doi.org/10.1109/ICMISI61517.2024.10580424>
- Hristov, V. D., Saliev, D. N., & Slavov, D. V. (2022). Artificial Intelligence Systems for Warehouses Stocks Control. *2022 8th International Conference on Energy Efficiency and Agricultural Engineering (EE&AE)*, 1–5. <https://doi.org/10.1109/EEAE53789.2022.9831223>
- Ines, J. C., Tolentino, M. Q., Cruz, J. C. D., Estabillo, R., Madlambayan, A. M., Mirano, C. E., & Vergara, J. A. (2024). The Role of AI in Enhancing Decision-Making in Small and Medium Enterprises (SMEs). *2024 2nd International Conference on Computing and Data Analytics, ICCDA 2024 - Proceedings*. <https://doi.org/10.1109/ICCDA64887.2024.10867356>

- Instituto Nacional de Estadística e Informática (INEI). (2022). *Arequipa albergó a 1 millón 316 mil habitantes*. Recuperado de <https://m.inei.gob.pe/prensa/noticias/arequipa-alberga-a-1-millon-316-mil-habitantes-9903/>?
- Jackson, I., Ivanov, D., Dolgui, A., & Namdar, J. (2024). Generative artificial intelligence in supply chain and operations management: A capability-based framework for analysis and implementation. *International Journal of Production Research*, 62(17), 6120-6145. <https://doi.org/10.1080/00207543.2024.2309309>
- JAR Abdelkarim, & SERGHINI Meryem. (2025). *Supply Chain Decision-Making: Complexity and Challenges*. <https://doi.org/10.5281/ZENODO.15873198>
- Kim, M., Lee, J., Lee, C., & Jeong, J. (2022). Framework of 2D KDE and LSTM-Based Forecasting for Cost-Effective Inventory Management in Smart Manufacturing. *Applied Sciences*, 12(5), 2380. <https://doi.org/10.3390/app12052380>
- Liu, M., Qi, M., & Shen, Z.-J. M. (2021). End-to-End Deep Learning for Inventory Management with Fixed Ordering Cost and its Theoretical Analysis. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3888897>
- Liu, R., & Vakharia, V. (2024). Optimizing Supply Chain Management Through BO-CNN-LSTM for Demand Forecasting and Inventory Management: *Journal of Organizational and End User Computing*, 36(1), 1-25. <https://doi.org/10.4018/JOEUC.335591>
- Liu, Y., Kalaitzi, D., Wang, M., & Papanagnou, C. (2025). A Machine learning Approach to Inventory Stockout Prediction. *Journal of Digital Economy*, S2773067025000202. <https://doi.org/10.1016/j.jdec.2025.06.002>

Microsoft News Center Latinoamérica. (2023). 95% de las Pymes peruanas considera que el proceso de transformación digital impacta positivamente en su negocio. Recuperado de [Source](#)

Ministerio de la Producción. (2023). Mipymes incrementan su productividad y rentabilidad haciendo uso de proyectos cofinanciados por Produce. Gobierno del Perú. Recuperado de [Gobierno del Perú+1Source+1](#)

Misari, M. A. (2012). *El control interno de inventarios y la gestión en las...* Universidad de San Martín de Porres. Recuperado de [Repositorio USMP+1Región Científica+1](#)

OECD/CAF/SELA. (2024). *SME Policy Index: Latin America and the Caribbean 2024: Towards an Inclusive, Resilient, and Sustainable Recovery*. OECD Publishing. <https://doi.org/10.1787/ba028c1d-en>

OpenAI. (2023). GPT-4 Technical Report. arXiv. <https://doi.org/10.48550/arXiv.2303.08774>

Ortega Arana, N. B. (2017). *Facultad de Ingeniería Industrial y de Sistemas*. Universidad Nacional Federico Villarreal. Recuperado de repositorio.unfv.edu.pe

Oviedo-Bayas, B., López-Robayo, E., & Zambrano-Vega, C. G. (2025). Artificial intelligence demand forecasting for improved inventory and fleet management. *Journal of business and entrepreneurial studie, 1*(3), 1-9. <https://doi.org/10.37956/jbes.v9i2.395>

Pampa Pariapaza, J. (2020). *Relación de la gestión de inventarios y el proceso comercial de la MYPE Artesanías Alpaca Fina EIRL Juliaca-Puno*. Universidad Continental. Recuperado de [Repositorio Continental](#)

Patil, P. S., Patil, S. S., Patil, S. M., & Dhanvijay, M. R. (2024). Development of MS Excel and Power BI Integrated Production Scheduling System for an MSME. *Engineering Access, 10*(2), 124–142. <https://doi.org/10.14456/mijet.2024.15>

Pérez Díaz, C. (2022). *Control de inventarios: utilidad e importancia en las mypes comerciales*.

Universidad Católica Santo Toribio de Mogrovejo. Recuperado de [ResearchGate+2Tesis USAT+2Revistas UNJBG+2](#)

Porfirio, T. C., Saul, M. A., & 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), 8140-8155.

<https://doi.org/10.56238/levv15n43-037>

Preil, D., & Krapp, M. (2022). Artificial intelligence-based inventory management: a Monte Carlo tree search approach. *Annals of Operations Research*, 308(1–2), 415–439.

<https://doi.org/10.1007/s10479-021-03935-2>

Prolyam. (2023). Software de Inventario en Arequipa | Todo lo que Necesitas Saber.

Recuperado de [Prolyam Software](#)

Quan, Y., & Liu, Z. (2024). *InvAgent: A Large Language Model based Multi-Agent System for Inventory Management in Supply Chains* (Versión 2). arXiv.

<https://doi.org/10.48550/ARXIV.2407.11384>

Rolf, B., Jackson, I., Müller, M., Lang, S., Reggelin, T., & Ivanov, D. (2023). A review on reinforcement learning algorithms and applications in supply chain management.

International Journal of Production Research, 61(20), 7151-7179.

<https://doi.org/10.1080/00207543.2022.2140221>

Rolón Ramírez, D. A. (2024). Transformación Tecnológica en el Modelo de Gestión de Inventarios en las Mipymes, Revisión Bibliográfica. *Ciencia Latina Revista Científica Multidisciplinar*, 8(1), 3551-3566.

https://doi.org/10.37811/el_rcm.v8i1.9701

- Saraogi, G., Gupta, D., Sharma, L., & Rana, A. (2019). An Un-Supervised Approach for Backorder Prediction Using Deep Autoencoder. *Recent Advances in Computer Science and Communications*, 14(2), 500–511. <https://doi.org/10.2174/2213275912666190819112609>
- Sathyabama, K., Raj, A. P. A., & Gukan, R. (2024). AI-Driven Expiry Prediction and Dynamic Pricing System for Retail Inventory Management Utilizing ARIMA and LSTM Models. *2024 International Conference on Emerging Research in Computational Science (ICERCS)*, 1–6. <https://doi.org/10.1109/ICERCS63125.2024.10895116>
- Srivastava, S. K., Routray, S., Bag, S., Gupta, S., & Zhang, J. Z. (2024). Exploring the Potential of Large Language Models in Supply Chain Management: A Study Using Big Data. *Journal of Global Information Management*, 32(1), 1-29. <https://doi.org/10.4018/JGIM.335125>
- Universidad Autónoma del Estado de Hidalgo. (s.f.). La entrevista cualitativa como técnica de investigación. Recuperado de <https://www.uaeh.edu.mx/scige/boletin/tlahuelilpan/n7/r1.html>
- Universidad de la Empresa. (2019). La encuesta como técnica de investigación, validez y confiabilidad. Recuperado de <https://ude.edu.uy/la-encuesta-como-tecnica-deinvestigacion-validez-y-confiabilidad/>
- TIPSE. (2021). Power BI para Pymes - Perú. Recuperado de [TIPSE](#)
- Tiwari, A., Pillai, J., & Janghel, R. R. (2025). Leveraging LSTM for precision inventory management by future demand forecasting. *Journal of Applied Research and Technology*, 23(1), 8-21. <https://doi.org/10.22201/icat.24486736e.2025.23.1.2508>

Zavaleta Castro, G. S., Zavaleta Castro, M. M., & Quilia Valerio, J. V. M. (2024). Control de inventarios y gestión rentable en mypes comerciales de calzados. *Economía & Negocios*, 6(1), 182–194. Recuperado de [Revistas UNJBG+1ResearchGate+1](#)



ANEXOS

ANEXO A. Encuesta *Pre-Test*

Encuesta *Pre-Test* sobre Gestión de Inventarios (antes de mostrar el prototipo con la implementación de LLM)

Figura 37
Encuesta Pre-Test Parte 1

Validación del Instrumento

Encuesta 1 – Pre-test (Antes de implementar el LLM)

Nombre: Fecha:

Razón Social: RUC:

Instrucciones: Marque su nivel de acuerdo con cada afirmación respecto a la situación actual de la gestión de inventarios en su empresa.

Escala: 1 = Totalmente en desacuerdo | 2 = En desacuerdo | 3 = Ni de acuerdo ni en desacuerdo | 4 = De acuerdo | 5 = Totalmente de acuerdo

1. Actualmente contamos con un sistema informático implementado para la gestión de inventarios.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

2. Uso regularmente sistemas informáticos para tomar decisiones sobre inventarios.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

3. Conoce que es LLM y sus beneficios.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

4. Las herramientas actuales responden de forma clara y útil a mis necesidades de información sobre inventario.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

5. Con el sistema actual se reducen los problemas de desabastecimiento.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Figura 38

Encuesta Pre-Test Parte 2

6. Con el sistema actual se reducen los problemas de sobrestock.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

7. El tiempo que tardo en decidir compras o reposiciones es adecuado con el sistema actual.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

8. Las recomendaciones o reportes actuales coinciden con las ventas reales observadas.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

9. Estoy satisfecho con las herramientas actuales para tomar decisiones de inventario.

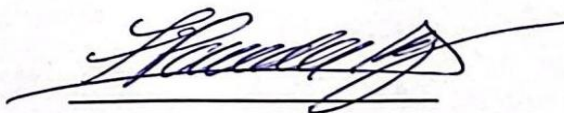
Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

10. En mi empresa las decisiones de inventario se toman principalmente por intuición. (ítem invertido)

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>



Firma
Karina Torres Porada
Apellidos y Nombre:



Firma
Fernando Peredes Merdinez.
Apellidos y Nombre:



Firma
Apellidos y Nombre:
Sullá Torres, José

ANEXO B. Encuesta *Post-Test*

Encuesta *Post-Test* sobre Gestión de Inventarios (después de mostrar el prototipo con LLM)

Figura 39
Encuesta Post-Test Parte 1

Validación del Instrumento

Encuesta 2 – Post-test (Después de mostrar el prototipo de LLM)

Nombre: **Fecha:**

Razón Social: **RUC:**

Instrucciones: Marque su nivel de acuerdo con cada afirmación respecto a la utilidad y efectividad del prototipo de sistema basado en LLM que se le ha mostrado.

Escala: 1 = Totalmente en desacuerdo | 2 = En desacuerdo | 3 = Ni de acuerdo ni en desacuerdo | 4 = De acuerdo | 5 = Totalmente de acuerdo

1. El prototipo con LLM presentado podría implementarse para mi empresa.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

2. Considero que utilizaría regularmente un sistema con LLM para tomar decisiones de inventario.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

3. El LLM mostrado en el prototipo ofrece predicciones con la precisión suficiente para planificar inventarios.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

4. El asistente conversacional del prototipo responde de forma clara y útil a las consultas sobre inventario.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

5. Un sistema como el prototipo, se reducirían los problemas de desabastecimiento en mi empresa.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Figura 40

Encuesta Post-Test Parte 2

6. Con un sistema como el prototipo, se reducirían los problemas de sobrestock.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

7. El sistema propuesto ayudaría a disminuir el tiempo que tardo en decidir compras o reposiciones.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

8. Las recomendaciones generadas por el LLM serían coherentes con las ventas reales de mi empresa.

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

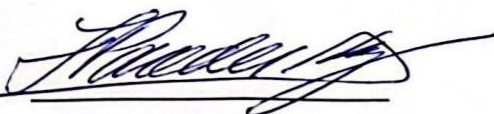
9. Estoy satisfecho con el prototipo presentado y lo considero útil para mejorar la toma de decisiones en inventario.


Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

10. En mi empresa seguiríamos tomando decisiones principalmente por intuición y no con base en un sistema LLM. *(item invertido)*

Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>


 Firma
 Rosas Paredes Kouina
 Apellidos y Nombre:


 Firma
 Fernando Paredes Marchena
 Apellidos y Nombre:


 Firma
 Apellidos y Nombre:
 Sullá Torres, José

ANEXO C. Conjunto de Datos

En este anexo se presenta el conjunto de datos utilizado para el análisis estadístico de la investigación. Los archivos corresponden a los resultados obtenidos en las encuestas aplicadas antes (*Pre-Test*) y después (*Post-Test*) de la implementación del sistema propuesto, aplicadas a 40 micro y pequeñas empresas (MYPES) comerciales de la ciudad de Arequipa.

Los datos fueron recopilados, organizados y procesados en formato CSV (*Comma Separated Values*), conteniendo los valores individuales por ítem, los promedios por empresa y las puntuaciones generales utilizadas para el análisis descriptivo e inferencial.

Figura 41
Conjunto de Datos de la Investigación – Pre-Test

A	B	C	E	F	G	H	I	J	K	L	M	N
ID	Empresa	RUC	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10
1	ELECTROSAVE	20100	3	3	3	4	3	3	4	4	3	4
2	ALDO PEREZ C	2055	3	3	3	1	1	2	2	3	2	3
3	COMERCIAL M	10047	4	3	3	2	3	3	2	3	2	4
4	CLASSICA JES	2017	2	5	2	2	4	2	3	1	2	4
5	DJEEXA E.I.R.L	2055	4	3	2	3	2	2	3	4	3	3
6	C & S LUCIANO	2045	3	3	2	4	4	4	2	3	3	4
7	GRUPO QUICK	2060	3	3	2	2	4	4	3	4	3	3
8	JENCAR & FUR	2060	3	4	2	4	1	4	3	3	3	2
9	LAS TRES VIRG	2060	3	3	4	3	2	3	4	3	3	4
10	CRÉDITOS PAZ	2060	3	4	2	3	3	2	3	3	3	4
11	CORPORACIÓN	2043	2	3	2	2	3	3	5	3	3	4
12	LA GRAN BOUT	2049	1	3	3	5	3	3	3	2	4	4
13	CORPORACIÓN	2060	4	2	4	2	4	5	2	2	3	3
14	RESANPE S.R.L	2045	2	3	2	3	2	4	2	3	4	3
15	SMILEYS E.I.R.L	2052	3	4	1	3	3	4	2	2	3	4
16	COMERCIAL TC	2013	3	3	2	3	3	2	5	3	2	4
17	AGRÍCOLA ARE	2060	2	4	4	2	4	3	4	5	3	3
18	COMERCIAL AF	2011	2	2	2	3	3	4	3	4	3	5
19	TEXTILES STAS	2045	2	4	3	2	2	4	1	3	4	3
20	IMPORTACIONE	2055	2	3	4	2	3	3	5	5	4	4
21	OXYTEX S.A.C	2045	4	4	2	4	2	2	4	2	3	3
22	CONFECCION C	2049	3	1	1	2	4	3	3	4	2	4
23	CONFECCIONE	2037	2	1	2	4	3	3	5	3	4	5
24	CONFECCIONE	2037	2	2	4	2	3	4	4	5	4	5
25	TEXTILES FRAI	2049	2	4	3	2	4	4	3	3	2	4
26	CONTRATISTAS	2057	3	2	3	2	1	4	3	3	2	3
27	CONFECCIONE	2045	4	2	4	4	3	2	2	2	5	4
28	1818 S.A.C	2050	4	2	3	4	3	4	2	2	3	4
29	REPUESTOS LI	2061	4	1	3	5	3	3	3	1	3	3
30	KATEA E.I.R.L	2060	3	4	2	3	4	3	2	3	5	2
31	REPUESTOS N	2045	3	3	2	4	4	3	4	3	3	3
32	REPUESTOS E	2045	2	2	2	3	4	3	3	5	4	4
33	FERRETERIA Y	2045	2	3	3	3	4	3	3	4	3	4
34	SIERRA AMPAT	2060	3	3	1	1	2	3	3	3	4	4
35	IMPORTACIONE	2060	3	3	3	4	4	2	4	2	3	4
36	MULTISERVICIO	2060	2	3	2	3	3	4	3	2	3	4
37	FERRO ELECTO	2061	3	4	4	3	3	1	3	2	3	4
38	FERRETERIA N	2061	3	3	3	3	3	1	3	3	3	4
39	SION FERRETE	2061	4	2	4	4	3	3	3	2	3	4
40	IMPORTACIONE	2060	4	4	2	2	2	4	4	3	2	4

Figura 42

Conjunto de Datos de la Investigación – Post-Test

ID	Empresa	RU	Ent	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	
1	ELECTROSAVE	201	Alb		5	4	3	5	4	5	5	4	4	1
2	ALDO PEREZ C	205	Ald		4	5	4	4	5	5	4	4	5	1
3	COMERCIAL M	100	We		5	5	5	5	4	4	5	5	5	4
4	CLASSICA JES	201	Gui		5	5	5	5	4	5	4	4	4	2
5	DIJEEXA E.I.R.L	205	Cin		5	3	4	4	4	5	5	4	4	2
6	C & S LUCIANO	204	Eln		4	5	4	4	5	5	3	5	4	2
7	GRUPO QUICK	206	Ant		4	4	4	5	4	4	4	4	5	2
8	JENCAR & FUR	206	Ver		4	5	5	5	3	4	5	4	5	2
9	LAS TRES VÍRC	206	Eln		4	4	2	4	4	4	5	4	4	2
10	CRÉDITOS PAZ	206	Thi		5	4	5	5	4	5	5	4	5	2
11	CORPORACIÓN	204	Rut		4	5	5	4	5	3	4	5	5	1
12	LA GRAN BOUT	204	Go		4	4	4	5	5	4	5	5	5	2
13	CORPORACIÓN	206	Ánt		4	4	4	5	4	4	5	4	5	2
14	RESANPE S.R.L	204	Ma		4	5	4	5	5	4	5	4	5	2
15	SMILEYS E.I.R.L	205	Edt		4	5	4	5	4	4	5	5	5	2
16	COMERCIAL TC	201	No		4	4	4	4	5	4	4	4	5	1
17	AGRÍCOLA ARE	206	No		4	5	4	4	4	5	4	4	4	2
18	COMERCIAL AF	201	No		5	5	5	4	4	4	4	4	5	1
19	TEXTILES STAS	204	Mil		4	4	4	4	5	4	4	4	4	2
20	IMPORTACIONE	205	Edt		3	5	4	5	5	4	5	4	5	2
21	OXYTEX S.A.C	204	Els		5	5	4	4	5	4	5	3	4	2
22	CONFECION	204	Luz		5	5	4	3	5	4	5	4	5	4
23	CONFECIONE	203	Vid		4	4	4	4	5	4	5	5	5	2
24	CONFECIONE	203	Jos		4	4	5	4	4	4	5	4	4	1
25	TEXTILES FRAI	204	Fra		4	4	3	4	4	4	4	5	4	2
26	CONTRATISTAS	205	Vil		4	5	5	4	3	5	5	5	5	2
27	CONFECIONE	204	Ro		5	4	4	5	4	5	4	5	5	2
28	1818 S.A.C	205	Abt		5	5	3	5	5	4	4	4	4	2
29	REPUESTOS LI	206	Rai		4	4	4	4	5	4	3	4	4	2
30	KATEA E.I.R.L	206	Juli		4	5	4	4	4	4	5	5	5	1
31	REPUESTOS N	204	Nai		4	4	5	4	3	4	4	5	4	3
32	REPUESTOS E	204	Pet		4	4	3	4	4	4	4	5	3	1
33	FERRETERIA Y	204	Roi		4	5	4	5	4	4	5	4	5	2
34	SIERRA AMPAT	206	Vic		3	4	5	5	4	5	4	5	5	1
35	IMPORTACIONE	206	Ge		5	4	3	4	4	4	4	5	5	1
36	MULTISERVICIO	206	Sin		5	5	4	4	3	4	4	5	4	2
37	FERRO ELECTI	206	Hai		5	4	4	4	4	5	3	4	5	2
38	FERRETERIA N	206	Bre		5	5	4	5	5	3	5	4	4	1
39	SION FERRETE	206	Hei		4	5	4	4	4	4	5	5	4	2
40	IMPORTACIONE	206	Tat		4	5	4	4	5	5	5	3	5	2