



TÍTULO DE LA INVESTIGACIÓN

“Propuesta de implementación de un sistema predictivo basado en machine learning para mejorar la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025”

TRABAJO DE INVESTIGACIÓN PARA OPTAR EL TÍTULO PROFESIONAL:

Bachiller en Dirección de Tecnologías de la información

PRESENTADO POR:

Guerra Torres, Jaime Jesus - Dirección de Tecnologías de la información

ASESOR

Peláez Valdivieso, José Víctor

LIMA, PERÚ

2025

ASESOR Y MIEMBROS DEL JURADO

ASESOR:

Peláez Valdivieso, José Víctor

MIEMBROS DEL JURADO

Ricra Mayorca, Juan Manuel

Saco Vértiz Osterloh, Sandra Elizabeth

Velasquez Tapullima, Pedro Alfonso



DECLARACIÓN JURADA DE ORIGINALIDAD

Yo, **Jaime Jesus Guerra Torres** identificado con DNI N° **45573196** perteneciente al Programa de **Dirección de Tecnologías de la información**, siendo mi asesor el Sr. **José Víctor Peláez Valdivieso**, identificado con DNI N° **18161446**, y cuyo código ORCID es **0000-0002-2186-0398**.

DECLARO BAJO JURAMENTO QUE:

- a) Soy el autor del documento académico titulado “**Propuesta de implementación de un sistema predictivo basado en *machine learning* para mejorar la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025.**“
- b) El trabajo de investigación es original y no ha sido difundido en ningún medio académico; por lo tanto, sus resultados son veraces y no es copia de ningún otro.
- c) El asesor ha revisado minuciosamente el trabajo de suficiencia profesional, incluyendo las citas a otros autores y las referencias bibliográficas. Este proceso se ha llevado a cabo cumpliendo con las pautas académicas y respetando las normas internacionales.
- d) El trabajo de investigación cumplió con el análisis del sistema TURNITIN, el cual tiene el **15%** de similitud.
- e) Declaro conocer las consecuencias legales y/o administrativas que puedan derivar si se verifica la falsedad total o parcial de la presente declaración, de acuerdo con lo previsto en el artículo 411 del código penal, el numeral 34.3 del artículo 34 del Texto Único Ordenado de la Ley del Procedimiento Administrativo General, aprobado por Decreto Supremo 004-2019-JUS y los artículos 14° y 15ª de la RVM 049-2022-MINEDU.

Fecha: **13, diciembre, 2025**



Firmal del autor

Huella

Firmal del asesor

Huella

Índice temático

Índice temático..... 4

Índice de tablas 8

Índice de figuras	9
Resumen	10
Abstract.....	11
Introducción.....	12
I. Información General.....	14
1.1. Título del proyecto	14
1.2. Línea de investigación.....	14
1.3. Actividad económica en la que se aplicaría la innovación o investigación aplicada	14
1.4. Localización o alcance de la solución	15
1.5. Enfoque de la investigación	15
II. Descripción de la investigación aplicada o innovación.....	15
2.1. Planteamiento del problema.....	15
2.1.1. Problemas de investigación	15
2.2. Justificación.....	16
2.2.1. Justificación teórica	16
2.2.2. Justificación metodológica	17
2.2.3. Justificación practica	18
2.3. Marco Referencial	19
2.3.1. Antecedentes de investigación	19
2.3.2. Marco teórico.....	22

2.3.3. Glosario de términos	33
2.4. Resumen ejecutivo	35
2.5. Características técnicas o atributos del proyecto	36
2.6. Análisis comparativo de atributos, características, mejoras o novedades tecnológicas	37
2.7. Objetivo general y específicos: propósito del proyecto	37
2.7.1. Objetivo general	37
2.7.2. Objetivos específicos	38
2.8. Componente del proyecto	38
2.9. Resultados generales: Componente del proyecto.....	39
2.10. Plan de actividades del proyecto.....	39
2.11. Metodología del proyecto	41
2.11.1. Hipótesis de la investigación	41
2.11.2. Operacionalización de variables.....	41
2.11.3. Enfoque de investigación.....	42
2.11.4. Tipo de investigación	43
2.11.5. Diseño de investigación.....	43
2.11.6. Nivel de investigación.....	43
2.11.7. Población.....	44
2.11.8. Muestreo y muestra.....	44

2.11.9. Técnicas e instrumentos de recolección de datos	44
2.11.10. Validez y confiabilidad	46
III. Estimación del costo del proyecto	47
3.1. Estimación de los costos necesarios para la implementación.....	47
IV. Análisis de resultados descriptivos	49
4.1. Análisis de datos cualitativos.....	49
V. Plan de implementación y viabilidad	61
5.1. Análisis del mercado	61
5.2. Descripción del mercado	62
5.3. Diagnostico FODA.....	64
5.4. Propuesta de valor	65
5.5. Análisis de beneficios	66
5.6. Plan de adopción tecnológica	67
5.7. Plan de actividades de implementación	68
5.8. Alianzas estratégicas.....	69
5.9. Plan de comunicación interna	69
VI. Conclusiones y recomendaciones.....	70
6.1. Conclusiones.....	70
6.1.1. Conclusiones generales	70
6.1.2. Conclusiones específicas	70

6.2. Recomendaciones.....	71
6.2.1. Recomendaciones generales.....	71
6.2.2. Recomendaciones específicas.....	72
VII. Referencias bibliográficas.....	73
VIII. Anexos.....	76
Anexo 01: Informe Turnitin.....	76
Anexo 02: Registro de impactos y resultados.....	77
Anexo 03: Matriz de consistencia.....	79
Anexo 04: Matriz de operacionalización de variables.....	80
Anexo 05: Instrumentos de recolección de datos.....	81

Índice de tablas

Tabla 1.....	36
Tabla 2.....	37
Tabla 3.....	46
Tabla 4.....	48
Tabla 5.....	49
Tabla 6.....	50

Tabla 7.....	52
Tabla 8.....	53
Tabla 9.....	54
Tabla 10.....	55
Tabla 11.....	57
Tabla 12.....	57
Tabla 13.....	59
Tabla 14.....	59
Tabla 15.....	62
Tabla 16.....	63
Tabla 17.....	64

Índice de figuras

Figura 1.....	24
Figura 2.....	25
Figura 3.....	27
Figura 4.....	30
Figura 5.....	51
Figura 6.....	53
Figura 7.....	56

Figura 8 58

Figura 9 60

RESUMEN

Esta investigación se plantea en Home Market Foods, una empresa de Estados Unidos dedicada a producir y distribuir alimentos congelados. En este negocio el inventario no solo es un tema de almacenes, sino, es un punto de riesgo diario: por la naturaleza perecible del producto, un error de estimación puede generar faltantes, exceso de stock y costos operativos altos en producción, almacenamiento y transporte. Por eso se propone implementar un sistema predictivo basado en Machine Learning que permita anticipar la demanda y mejorar los tiempos de reabastecimiento, conectándose directamente con el ERP corporativo Microsoft Dynamics 365 para que el pronóstico se traduzca en decisiones dentro del flujo normal. El **objetivo** principal es aterrizar si esta solución es viable en la operación, tanto por el lado técnico como por cómo se trabaja en el

día a día, y confirmar si el sistema realmente genera valor y no se queda en teoría. Se desarrollará la investigación con un **enfoque cualitativo, descriptivo y aplicado**: se usará una guía de entrevistas con colaboradores que participan en decisiones y tareas administrativas clave, y en paralelo se revisará información histórica del ERP. Esto último se realizó de manera superficial solo para corroborar con grandes números la percepción que los colaboradores perciben sobre el proceso, cómo se muestran los datos, para medir a grosso modo cuánto beneficio se obtendría con decisiones tomadas con ayuda de un modelo predictivo. Los resultados obtenidos demostraron que la empresa ve como viable la implementación de un sistema predictivo basado en ML, aunque se identificaron factores de riesgo que dificultarían, por no decir imposibilitarían, su desarrollo, principalmente ligados a la cultura y confianza de datos. Finalmente, **la propuesta** se plantea como un punto de partida escalable, aplicable también a otras empresas del sector alimenticio u otras industrias con problemas similares de inventario.

Palabras claves: Machine Learning, gestión de inventarios, sistema predictivo, transformación digital.

ABSTRACT

This research is being conducted at Home Market Foods, a US company that produces and distributes frozen foods. In this business, inventory is not just a warehouse issue, but a daily risk factor: due to the perishable nature of the product, an estimation error can lead to shortages, excess stock, and high operating costs in production, storage, and transportation. Therefore, the proposal is to implement a predictive system based on Machine Learning that anticipates demand and improves replenishment times, connecting directly with the corporate ERP system, Microsoft Dynamics 365, so that the forecast translates into decisions within the normal workflow. The main **objective** is to determine if this solution is viable in the operation, both from a technical standpoint and in terms of daily workflow, and to confirm whether the system truly generates value and is not merely theoretical. The research will be conducted with a **qualitative, descriptive, and applied approach**: an interview guide will be used with employees involved in key administrative

decisions and tasks, and historical data from the ERP system will be reviewed concurrently. This last step was carried out superficially, solely to corroborate, with a large number of samples, the perception employees have of the process as presented in the data, in order to roughly measure the potential benefit of decisions made with the help of a predictive model. The results obtained demonstrated that the company sees the implementation of a predictive system based on machine learning as viable, although risk factors were identified that would hinder, if not prevent, its development, mainly related to culture and data trust. Finally, **the proposal** is presented as a scalable starting point, also applicable to other companies in the food sector or other industries with similar inventory problems.

Keywords: Machine Learning, inventory management, predictive system, digital transformation.

Introducción

Hoy en día la gestión de inventarios es un factor clave para competir, y en la industria alimentaria se vuelve aún más delicada porque el producto es perecible y el abastecimiento tiene que ser preciso. Cuando el inventario se maneja mal, normalmente pasa lo mismo: se pierde dinero por merma y desperdicio, aparecen quiebres de stock que afectan al cliente, o se termina pagando de más por almacenar producto innecesario.

Home Market Foods, ubicada en Norwood, Massachusetts (EE. UU.), vive estos retos de frente en la gestión de alimentos congelados y perecibles: la demanda cambia todo el tiempo y la competencia obliga a responder más rápido y con menos margen de error. Por ello, el Machine Learning se vuelve una opción práctica porque ayuda a armar modelos que anticipen la demanda, ajusten mejor los tiempos de reabastecimiento y

bajen costos operativos, aunque esto significa retos de adaptación y adopción en los equipos de trabajo, todo esto, siguiendo la línea de la transformación digital que hoy se está aplicando en la cadena de suministro y otras áreas.

La investigación propuesta se centra en analizar la factibilidad de implementar un sistema predictivo orientado a la gestión de inventarios en la organización. Para ello, se plantean objetivos específicos orientados a analizar su impacto en la disponibilidad de productos, eficiencia de los procesos logísticos y reducción de costos asociados al abastecimiento. El enfoque metodológico será cualitativo y descriptivo, privilegiando la recolección de percepciones de colaboradores estratégicos complementadas con registros históricos del ERP corporativo.

Con esta propuesta se busca aportar a la mejora de los procesos internos de Home Market Foods, fortalecer su capacidad de respuesta en un entorno dinámico y, al mismo tiempo, generar un modelo de innovación tecnológica aplicable a otras organizaciones del sector.

I. Información General

1.1. Título del proyecto

Propuesta de implementación de un sistema predictivo basado en Machine Learning para mejorar la gestión de inventarios en la empresa Home Market Foods, Estados Unidos – 2025.

1.2. Línea de investigación

La investigación se centra en aplicar tecnologías de Machine Learning para la **mejora de procesos y operaciones** de gestión de inventarios y cadena de suministros. El foco está en proponer la transformación digital de la cadena de suministro y optimizar operaciones, buscando una solución que haga más eficiente el trabajo diario y ayude a competir mejor en un entorno cada vez más exigente y global.

1.3. Actividad económica en la que se aplicaría la innovación o investigación aplicada

Home Market Foods se dedica a la producción y distribución de alimentos, lo que implica una gestión compleja de inventarios. La investigación aplica en esta actividad económica porque un manejo ineficiente genera pérdidas por desperdicio, sobrecostos

de almacenamiento o desabastecimiento, afectando directamente la rentabilidad y satisfacción del cliente.

1.4. Localización o alcance de la solución

La propuesta se implementará en la sede de Home Market Foods, pero posee potencial de escalabilidad hacia otras plantas de producción y empresas del sector alimenticio en diferentes países. El alcance considera la integración con sistemas ERP (como Microsoft Dynamics 365) y la incorporación futura de tecnologías de IoT y analítica en tiempo real

1.5. Enfoque de la investigación

El estudio busca comprender percepciones y barreras culturales de los colaboradores estratégicos frente a la adopción de un sistema predictivo, mediante entrevistas semiestructuradas. Al mismo tiempo, se apoya en el análisis de datos históricos del ERP para validar la utilidad del modelo. Este enfoque mixto, aunque con predominancia cualitativa, permite describir en profundidad las características de la gestión de inventarios y el potencial impacto de las soluciones de Machine Learning.

II. Descripción de la investigación aplicada o innovación

2.1. Planteamiento del problema

2.1.1. Problemas de investigación

2.1.1.1. Problema general

¿Cuáles son los factores que determinan la viabilidad de implementar un sistema predictivo basado en Machine Learning para optimizar la gestión de inventarios en la empresa Home Market Foods, Estados Unidos, 2025?

2.1.1.2. Problemas específicos

- ¿Qué factores técnicos y organizacionales influyen en la viabilidad de implementar un sistema predictivo basado en machine learning para mejorar la disponibilidad de productos en Home Market Foods?
- ¿Qué condiciones operativas y tecnológicas deben considerarse para que un sistema predictivo basado en Machine Learning optimice los tiempos de reabastecimiento en Home Market Foods?
- ¿Qué aspectos económicos y logísticos determinan la viabilidad de un sistema predictivo basado en Machine Learning para reducir los costos asociados al abastecimiento en Home Market Foods?

2.2. Justificación

2.2.1. Justificación teórica

La gestión de inventarios ha sido ampliamente estudiada mediante modelos clásicos como EOQ (Economic Order Quantity) o MRP (Material Requirements Planning), los cuales buscan optimizar los niveles de stock bajo supuestos de demanda estable y procesos lineales (Silver, Pyke & Thomas, 2017; Waters, 2003). Sin embargo, dichos enfoques presentan limitaciones en contextos actuales caracterizados por una alta variabilidad en la demanda y cadenas de suministro globalizadas (EY Perú, 2021; Cámara de Comercio de Lima, 2021).

En este escenario, la incorporación de técnicas de Machine Learning ofrece un valor diferencial, al permitir integrar múltiples variables (históricos de ventas, estacionalidad, tendencias de consumo y desempeño de proveedores) para generar predicciones más precisas en tiempo real (Vandeput, 2021; Géron, 2019). Investigaciones recientes

demuestran que la analítica predictiva puede mejorar significativamente la planificación de inventarios, optimizando tanto la rentabilidad como la eficiencia operativa (Barletti, Estrada & Verona, 2023; Hidalgo, 2024).

De esta forma, la presente investigación se justifica teóricamente porque amplía el conocimiento existente en el campo de la gestión de inventarios, proponiendo un enfoque innovador que combina teoría de operaciones, ciencia de datos y transformación digital. Además, fortalece el marco conceptual de la analítica aplicada en supply chain, abriendo camino para futuras investigaciones sobre el uso de algoritmos predictivos en sectores de bienes perecibles (Weinke, 2022; DeLuke, 2018).

2.2.2. Justificación metodológica

Metodológicamente, la investigación adopta un **diseño descriptivo, aplicado y de corte transversal**, con un **enfoque cualitativo** complementado con el análisis de datos históricos extraídos del ERP corporativo. Esta elección responde a la necesidad de comprender tanto la percepción de los colaboradores estratégicos sobre la viabilidad del sistema predictivo, como el comportamiento real del inventario en Home Market Foods.

El valor metodológico radica en la integración de entrevistas semiestructuradas con responsables de logística, compras y planificación, junto con el análisis documental del ERP Microsoft Dynamics 365, que centraliza las operaciones de la empresa desde 2024. De este modo, se logra una triangulación de información combinando datos subjetivos (percepciones, barreras culturales, disposición al cambio) con datos objetivos (patrones

de demanda, tiempos de reabastecimiento, costos asociados), lo que refuerza la validez del estudio (Figuerola & Reyes, 2022).

Asimismo, estudios recientes en contextos empresariales peruanos evidencian la utilidad de los métodos mixtos y del análisis de datos cualitativos para evaluar la aplicabilidad de soluciones predictivas antes de su implementación (Yato & Zamudio, 2024; Alarcón & Arteaga, 2024). Esta aproximación metodológica garantiza la confiabilidad del proceso investigativo y ofrece una base replicable para futuras evaluaciones de viabilidad tecnológica en otros sectores industriales.

2.2.3. Justificación practica

La relevancia práctica de este proyecto se centra en su potencial impacto sobre la eficiencia operativa de Home Market Foods. Una gestión predictiva de inventarios permitirá anticipar faltantes y excesos, reducir costos de almacenamiento, optimizar tiempos de reabastecimiento y mejorar la satisfacción del cliente al garantizar la disponibilidad de productos perecibles (Hidalgo, 2024; Barletti et al., 2023).

Además, la propuesta es escalable: aunque inicialmente se aplicará en la planta de Norwood, Massachusetts, puede adaptarse a otras sedes de la empresa o incluso a distintas industrias que enfrenten retos similares en su cadena de suministro. Este tipo de soluciones ya ha mostrado resultados positivos en sectores como minería, manufactura y retail (Yato & Zamudio, 2024; Figuerola & Reyes, 2022; Barroso, 2018).

Finalmente, la investigación ofrece un aporte estratégico al alinear la organización con la tendencia global hacia la transformación digital, dotándola de herramientas tecnológicas que incrementen su competitividad en un entorno dinámico y de alta exigencia (EY Perú,

2021; Weinke, 2022). En suma, el estudio no solo atiende una necesidad operativa puntual, sino que genera un modelo replicable de innovación tecnológica con beneficios medibles en reducción de costos, eficiencia logística y resiliencia organizacional.

2.3. Marco Referencial

2.3.1. Antecedentes de investigación

2.3.1.1. Antecedentes nacionales

En el contexto peruano, la gestión de inventarios ha sido abordada en investigaciones recientes que combinan metodologías tradicionales con herramientas tecnológicas emergentes.

Alarcón y Arteaga (2024), en su tesis titulada “Propuesta de mejora en la gestión de inventario usando herramientas de Lean Warehousing y Machine Learning de una empresa mayorista de equipos de automatización e instrumentación”, tuvieron como objetivo general diseñar una propuesta de mejora en la gestión de inventarios integrando técnicas de Lean Warehousing y algoritmos de Machine Learning para reducir errores de pronóstico y optimizar los recursos logísticos. La metodología empleada fue de tipo aplicada, con un enfoque cuantitativo-descriptivo, sustentada en el análisis de indicadores de desempeño y simulaciones de modelos predictivos. Los resultados demostraron que la aplicación de Machine Learning redujo en un 50 % los errores de pronóstico y que la metodología 5S incrementó en un 90 % la exactitud de los registros de inventario. Se concluyó que la integración de herramientas tecnológicas y de gestión permite mejorar la eficiencia operativa y la trazabilidad de la información en los procesos de almacén, generando una ventaja competitiva sostenible para la organización peruana analizada.

Yato y Zamudio (2024) desarrollaron el estudio “Modelo de gestión de inventarios para el abastecimiento de repuestos de una flota de operaciones aplicando Machine Learning en una mina subterránea del sur del Perú”, cuyo objetivo general fue diseñar un modelo predictivo de gestión de inventarios basado en Machine Learning para optimizar el abastecimiento de repuestos críticos. La metodología utilizada fue aplicada, de tipo descriptivo y no experimental, empleando el método ABC para la clasificación de repuestos y la implementación de modelos de regresión lineal y Random Forest en el entorno Python (Google Colab). Los resultados indicaron que el modelo Random Forest logró una mayor precisión en las predicciones de demanda, reduciendo significativamente los riesgos de desabastecimiento. En conclusión, se evidenció que el uso de Machine Learning mejora la disponibilidad de componentes críticos, favorece la planificación del mantenimiento y reduce los costos asociados al inventario minero.

Figuroa y Reyes (2022), en su investigación titulada “Gestión de Inventarios a través del Business Intelligence en una empresa del sector Retail: Caso Mumuso”, tuvieron como objetivo general proponer un modelo de gestión de inventarios basado en Business Intelligence (BI) con capacidad predictiva superior al 95 %. La metodología fue descriptiva y propositiva, empleando el método de estudio de caso con enfoque mixto. Se aplicaron encuestas al gerente de operaciones, jefes de tienda y clientes, complementadas con análisis de datos históricos del ERP. Los resultados demostraron que el modelo semántico de BI colaborativo mejoró la precisión de los pronósticos de demanda y redujo los quiebres de stock en más de un 30 %. Se concluyó que el uso de BI en la gestión de inventarios del sector retail permite una toma de decisiones más ágil,

reduce la incertidumbre operativa y fortalece la competitividad empresarial en mercados dinámicos.

En conjunto, estos antecedentes nacionales resaltan la necesidad y efectividad de aplicar técnicas de Machine Learning y herramientas analíticas en la gestión de inventarios, especialmente en sectores con alta variabilidad de demanda y costos logísticos elevados.

2.3.1.2. Antecedentes internacionales

A nivel internacional, diversas investigaciones destacan el potencial de los sistemas predictivos en la optimización de inventarios y la logística.

DeLuke (2021), en su tesis del Massachusetts Institute of Technology titulada “Predictive Modeling and Optimization of Autoinjector Manufacturing”, tuvo como objetivo general desarrollar un modelo predictivo para optimizar la fabricación de autoinyectores médicos mediante el uso de datos de procesos y componentes. La metodología fue cuantitativa, basada en la aplicación de algoritmos de aprendizaje supervisado (XGBoost) y simulaciones de emparejamiento de lotes de componentes. Los resultados mostraron una reducción del 35 % al 45 % en la variabilidad de parámetros críticos del producto final. La conclusión principal establece que los modelos predictivos permiten optimizar la planificación de la producción y mejorar la calidad del producto mediante decisiones basadas en datos.

Barroso (2018), en su investigación de la Universidad de Chile titulada “Modelo predictivo basado en Machine Learning de órdenes de trabajo riesgosas para mantenimiento de equipos mineros”, tuvo como objetivo general desarrollar un modelo predictivo para

identificar órdenes de mantenimiento con alto riesgo de falla en operaciones mineras. La metodología consistió en un diseño experimental aplicado, utilizando el algoritmo Gradient Boosting Trees y un conjunto de datos históricos de mantenimiento. Los resultados alcanzaron un 82.2 % de precisión en la identificación de órdenes riesgosas. En conclusión, se verificó que el uso de Machine Learning en la minería mejora la gestión del mantenimiento preventivo y permite anticipar riesgos operativos.

Weinke (2022), en su tesis doctoral de la Technische Universität Berlin titulada “Machine Learning im Logistikmanagement – Entwicklung eines Gestaltungsansatzes zum Einsatz von ML-Anwendungen in logistischen Entscheidungsprozessen”, tuvo como objetivo general desarrollar un marco metodológico para la aplicación de Machine Learning en la toma de decisiones logísticas. La metodología adoptó un enfoque mixto, combinando revisión sistemática de literatura, entrevistas con expertos y estudios de caso de empresas europeas. Los resultados revelaron que el éxito de las implementaciones de Machine Learning en logística depende tanto de la calidad de los datos como de la integración cultural y organizacional. En conclusión, el autor propone un modelo de adopción estratégica que integra factores humanos, tecnológicos y organizativos para maximizar el impacto de la analítica predictiva en la gestión logística.

Estos antecedentes internacionales evidencian que las técnicas de Machine Learning poseen una alta capacidad de adaptación a distintos sectores (farmacéutico, minero, logístico), aportando precisión en los pronósticos y eficiencia en la toma de decisiones estratégicas.

2.3.2. Marco teórico

2.3.2.1. Gestion de inventarios

2.3.2.1.1. Conceptos fundamentales de la gestión de inventarios

El inventario se define como el conjunto de bienes, materiales, insumos y productos terminados que una empresa mantiene con el fin de atender la demanda actual y futura. Según Waters (2003), constituye un elemento clave de la operación porque permite dar continuidad al proceso productivo y cumplir con los requerimientos del cliente.

Silver et al. (2017) señalan que la gestión de inventarios busca un equilibrio entre la disponibilidad de productos y la minimización de costos, considerando factores como almacenamiento, deterioro, obsolescencia y logística. Una gestión deficiente puede derivar en desabastecimientos que afectan la satisfacción del cliente, o en sobreabastecimientos que incrementan los costos y el riesgo de pérdidas, particularmente en el caso de productos perecibles como los de la industria alimentaria.

En este contexto, Home Market Foods enfrenta retos propios de la producción y distribución de alimentos congelados, donde la precisión en el manejo de inventarios es crítica para evitar pérdidas económicas, desperdicios o quiebres de stock.

2.3.2.1.2. Modelos clásicos de gestión de inventarios

2.3.2.1.2.1. Modelo EOQ (Economic Order Quantity)


El modelo EOQ, desarrollado por Harris (1913), es uno de los más utilizados en la administración de inventarios. Busca calcular la cantidad óptima de pedido que minimice el costo total de inventario, considerando el equilibrio entre costos de pedido (relacionados con la frecuencia de órdenes) y costos de mantenimiento (relacionados con el almacenamiento de productos).

Aunque este modelo ha sido ampliamente aplicado en entornos industriales, su principal limitación radica en asumir una demanda constante y predecible, lo cual resulta poco realista en industrias dinámicas y con alta variabilidad de consumo, como la de alimentos perecibles.

La relación entre estos componentes puede observarse en la figura 1, donde se representa gráficamente el comportamiento de los costos de pedido, mantenimiento y costo total en función de la cantidad de pedido. El punto de intersección entre las curvas de costos determina la cantidad óptima de pedido, que corresponde al nivel donde el costo total del inventario es mínimo (Waters, 2003).

Figura 1

Variación de costos con modelo EOQ



Nota: Waters, 2003

2.3.2.1.2.2. Modelo MRP (Material Requirements Planning)

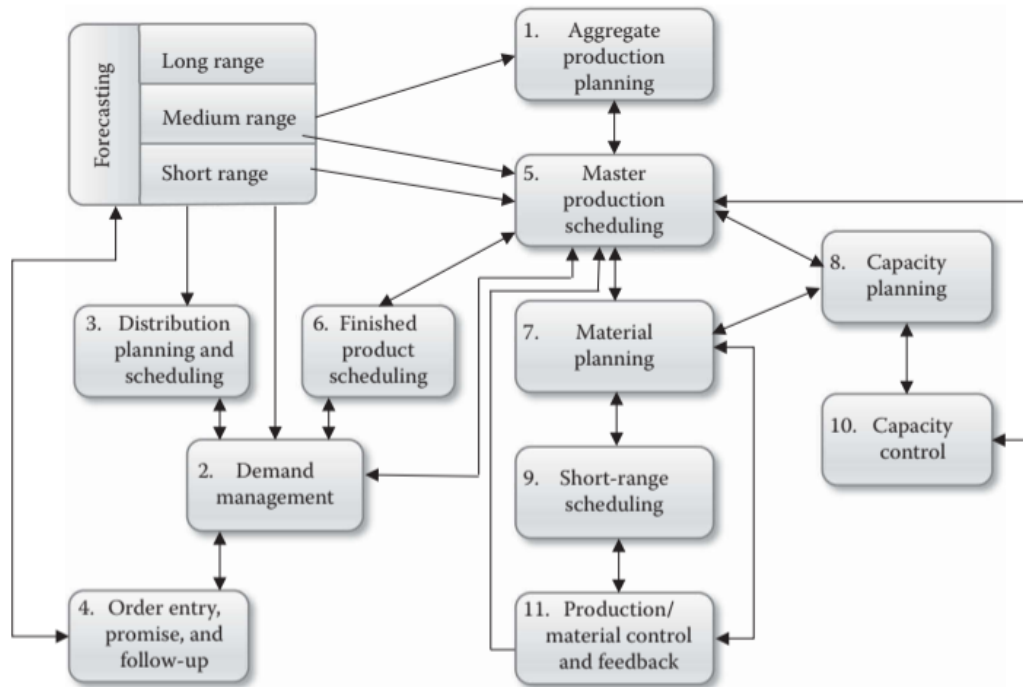
El MRP surge en la década de 1960 junto con los sistemas computacionales de planificación. Su propósito es asegurar la disponibilidad de materiales y componentes en el momento exacto en que se requieren, evitando interrupciones en la producción (Silver et al., 2017).

El sistema MRP utiliza como insumos la demanda dependiente (productos intermedios y materias primas que dependen de un producto final), los tiempos de aprovisionamiento y los niveles de inventario existentes. De esta manera, permite planificar compras y producción de manera más eficiente.

El proceso del MRP puede visualizarse de forma esquemática como un sistema de planificación en ciclo cerrado, en el cual las distintas etapas —desde la previsión de la demanda hasta el control de capacidad— se retroalimentan de manera continua para garantizar la disponibilidad oportuna de materiales. En la figura 2 se ilustra este flujo integrado de planificación, que refleja la interacción entre pronósticos, programación maestra, planificación de materiales y control de la producción (Silver et al., 2017).

Figura 2

Planificación de necesidades de materiales en ciclo cerrado



Nota: Silver et al., 2017

Sin embargo, su eficacia depende de la calidad de los datos y de que la demanda prevista sea relativamente estable, lo que constituye una limitación importante en sectores como el de alimentos, donde los cambios en los hábitos de consumo y factores estacionales pueden alterar drásticamente las proyecciones.

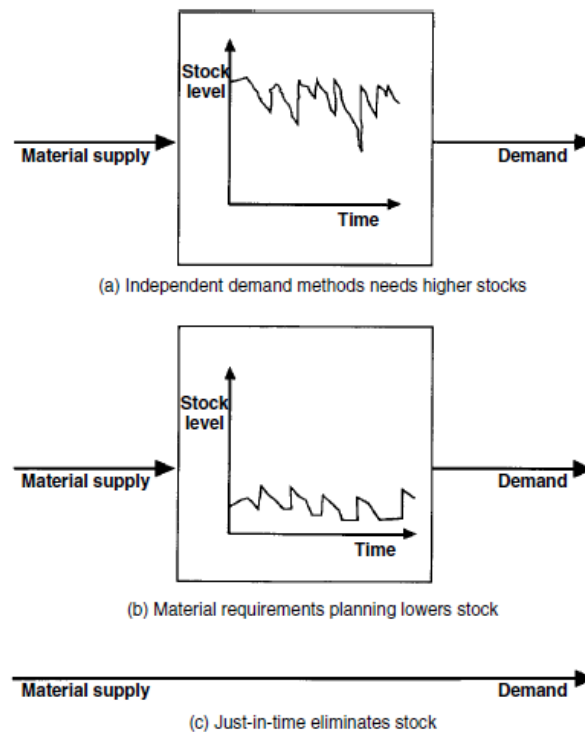
2.3.2.1.2.3. Modelo JIT (Just In Time)

El modelo Just in Time (JIT), originado en Japón e impulsado por Toyota en la década de 1970, busca minimizar los inventarios produciendo y entregando solo lo necesario, en el momento y en la cantidad exacta (Silver et al., 2017). Este enfoque reduce costos de almacenamiento, elimina desperdicios y fomenta la eficiencia en toda la cadena de suministro.

El modelo Just in Time redefine la gestión de inventarios al considerar el stock como un desperdicio que debe eliminarse mediante la sincronización entre oferta y demanda. A diferencia de otros enfoques, busca suprimir las causas de acumulación de inventarios para lograr una producción ágil y eficiente. La figura 3 muestra cómo este enfoque reduce progresivamente los niveles de stock hasta eliminarlos por completo (Waters, 2003).

Figura 3

Comparación de los niveles de existencias con diferentes enfoques de control de inventario



Nota: Waters, 2003

No obstante, su aplicación implica altos niveles de coordinación con proveedores, sistemas logísticos confiables y procesos productivos estandarizados. En el caso de los alimentos congelados, la implementación del JIT puede resultar riesgosa si existen fallas en la cadena de suministro, dado que un retraso puede generar desabastecimientos que impacten directamente en el cliente final (Waters, 2003).

2.3.2.1.3. Tecnología en gestión de inventarios

2.3.2.1.3.1. ERP (Enterprise Resource Planning)

Los sistemas de planificación de recursos empresariales, conocidos como ERP (Enterprise Resource Planning), constituyen una de las herramientas más relevantes en la gestión organizacional moderna. Su propósito principal es integrar en un único entorno digital los procesos claves de una empresa, tales como finanzas, producción, ventas, logística y gestión de inventarios. Gracias a esta integración, el ERP proporciona una visión centralizada de la operación y facilita la toma de decisiones basada en información confiable y en tiempo real (Monk & Wagner, 2013).

En el ámbito específico de los inventarios, los ERP cumplen un rol esencial al permitir el control de existencias, la definición de niveles mínimos y máximos de stock, la planificación de reabastecimientos y el seguimiento de entradas y salidas en los almacenes. Estos sistemas, además, se interrelacionan con los módulos de compras, producción y logística, automatizando órdenes de pedido y vinculando la disponibilidad de materiales con las necesidades productivas y de distribución. Como resultado, el uso de ERP incrementa la eficiencia operativa, disminuye los errores humanos en el registro y control de inventarios y fortalece la trazabilidad de los productos a lo largo de la cadena de suministro (Laudon & Laudon, 2020).

Sin embargo, los ERP también presentan limitaciones importantes. Entre ellas se encuentran los altos costos de implementación, que pueden representar una barrera para pequeñas y medianas empresas, así como la dependencia de la calidad de los datos registrados. Además, la mayoría de estas plataformas están orientadas a la gestión transaccional y al control operativo, por lo que carecen de capacidades predictivas

avanzadas. Esto significa que, si bien permiten registrar y organizar datos, no poseen de manera nativa herramientas analíticas que anticipen variaciones de la demanda o proyecten escenarios futuros de manera.

2.3.2.1.3.2. Microsoft Dynamics 365

Microsoft Dynamics 365 es una de las plataformas ERP más utilizadas a nivel corporativo, ya que combina funcionalidades de gestión empresarial (ERP) con herramientas de relación con clientes (CRM) en un entorno modular y basado en la nube. Su diseño permite integrar de manera flexible áreas estratégicas como finanzas, operaciones, ventas, compras y servicio al cliente, lo que la convierte en una solución escalable para empresas de diversos tamaños y sectores.

En el campo de la gestión de inventarios, Dynamics 365 ofrece funcionalidades avanzadas que incluyen la integración en tiempo real de datos provenientes de ventas, producción y compras, así como la automatización de procesos logísticos como reabastecimientos programados y gestión de almacenes. La plataforma también incorpora capacidades de trazabilidad que resultan críticas en industrias altamente reguladas, como la alimentaria, donde se deben cumplir normativas de seguridad y calidad. A ello se suma el uso de paneles de control y reportes analíticos que permiten a los responsables de la cadena de suministro monitorear de forma inmediata los niveles de stock y el estado de los procesos operativos (Microsoft, 2023).

En el caso de Home Market Foods, la implementación de Dynamics 365 en 2024 significó un avance significativo en la digitalización de sus procesos de gestión de inventarios. La plataforma permitió centralizar la información de inventario, ventas y producción en un

único sistema, lo que generó la base de datos necesaria para la integración con modelos de Machine Learning y el desarrollo de soluciones predictivas. No obstante, Dynamics 365 comparte una limitación común con otros ERP: su orientación hacia el control transaccional y la ausencia de capacidades predictivas nativas. Esto obliga a complementarlo con herramientas externas de analítica avanzada que potencien la gestión de inventarios con proyecciones futuras y modelos de optimización.

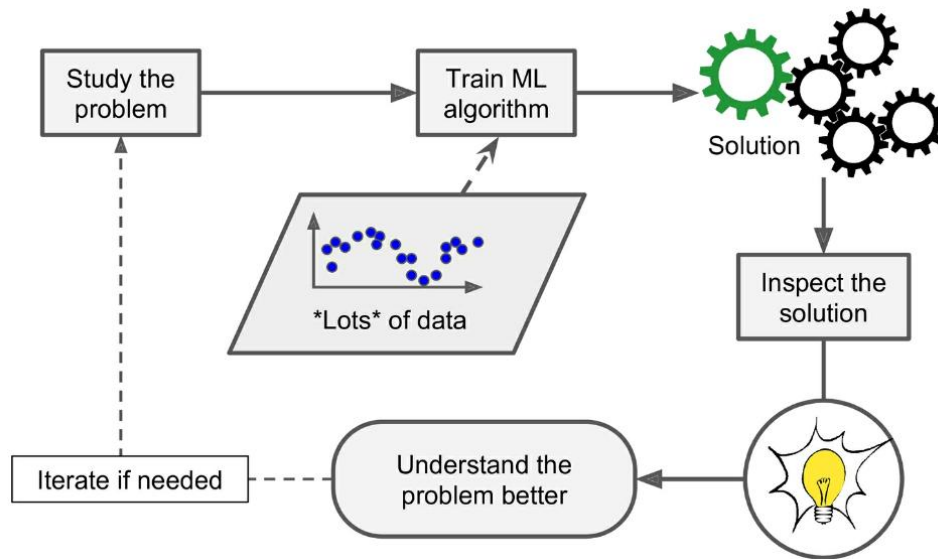
2.3.2.2. Machine Learning

2.3.2.2.1. Concepto de Machine Learning

El *Machine Learning* (ML), o aprendizaje automático, es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos capaces de aprender patrones a partir de datos y realizar predicciones sin necesidad de programación explícita. Según Géron (2019), los sistemas de ML utilizan grandes volúmenes de información histórica para generar modelos predictivos que permiten anticipar comportamientos futuros y mejorar la toma de decisiones estratégicas y operativas. Como se muestra en la Figura 4, el proceso de aprendizaje automático implica un ciclo iterativo de análisis del problema, entrenamiento del modelo, evaluación de resultados y ajuste continuo a partir de nuevos datos, lo que posibilita una mejora progresiva del desempeño del sistema. Esta capacidad adaptativa convierte al ML en una herramienta clave para entornos dinámicos como la gestión de inventarios, donde la variabilidad de la demanda y la incertidumbre logística exigen un alto nivel de precisión y flexibilidad (Géron, 2019).

Figura 4

Machine Learning puede ayudar a los humanos a aprender



Nota: Géron, 2019

2.3.2.2. Principales Algoritmos de Machine Learning

Los algoritmos de ML se clasifican en distintas categorías según el tipo de problema que buscan resolver. Entre los más utilizados en la gestión de inventarios se encuentran:

El primero es la regresión lineal, que permite identificar relaciones entre variables históricas y proyectar tendencias futuras, siendo útil para analizar la demanda en función de factores estacionales o promociones comerciales. Otro enfoque ampliamente aplicado es el Random Forest, que utiliza múltiples árboles de decisión para generar predicciones más robustas y precisas, especialmente en escenarios con datos complejos y no lineales. Asimismo, los modelos de redes neuronales artificiales (ANN) han cobrado relevancia por su capacidad de detectar patrones ocultos en grandes volúmenes de información, lo que resulta crítico para empresas con múltiples líneas de productos y alta rotación de inventarios. Finalmente, los modelos ARIMA y SARIMA, comúnmente

aplicados en series temporales, permiten anticipar tendencias en la demanda considerando factores de estacionalidad y periodicidad.

Cada uno de estos algoritmos presenta fortalezas y limitaciones, pero en conjunto conforman un marco analítico capaz de superar las restricciones de los modelos clásicos de gestión de inventarios, aportando predicciones dinámicas y de mayor precisión.

2.3.2.2.3. Aplicaciones de Machine Learning en la Gestión de Inventarios

El uso de Machine Learning en la gestión de inventarios se ha consolidado como una estrategia clave para mejorar la eficiencia de la cadena de suministro. Según Vandeput (2021), estas herramientas permiten integrar múltiples fuentes de datos — históricos de ventas, tendencias de consumo, desempeño de proveedores e información logística— para anticipar con mayor exactitud la demanda futura. Esta capacidad predictiva impacta directamente en la reducción de costos asociados al sobreabastecimiento, la prevención de faltantes y la optimización de los tiempos de reabastecimiento.

En el caso de la industria alimentaria, donde los productos son perecibles, el ML cobra especial relevancia porque reduce pérdidas por caducidad y mejora la disponibilidad en puntos de venta. Además, la integración de modelos predictivos con plataformas ERP, como Microsoft Dynamics 365, facilita la automatización de procesos y la generación de alertas tempranas frente a posibles quiebres de stock. Para Home Market Foods, esta aplicación constituye una oportunidad estratégica para transformar la gestión de inventarios en un proceso más ágil, confiable y alineado con las exigencias del mercado.

2.3.2.2.4. Ventajas y Limitaciones del Machine Learning en Inventarios

La principal ventaja del ML radica en su capacidad para aprender y adaptarse continuamente a nuevas condiciones del mercado, mejorando la precisión de los pronósticos en comparación con los modelos tradicionales. Además, permite gestionar grandes volúmenes de datos en tiempo real, identificar patrones complejos y ofrecer soluciones escalables que pueden aplicarse a distintas industrias. Este enfoque no solo optimiza los procesos internos, sino que también mejora la satisfacción del cliente al garantizar la disponibilidad de productos y reducir los tiempos de respuesta.

No obstante, el ML también enfrenta limitaciones. La dependencia de datos de calidad constituye uno de los principales desafíos, ya que errores o vacíos en los registros pueden afectar significativamente la efectividad de los modelos. Asimismo, la implementación de estas soluciones requiere una inversión considerable en infraestructura tecnológica y en capacitación del personal, lo que puede generar barreras para su adopción en organizaciones con recursos limitados. Finalmente, existe una curva de aprendizaje organizacional asociada a la adopción de nuevas tecnologías, que exige un cambio cultural hacia la confianza en sistemas automatizados para la toma de decisiones

2.3.3. Glosario de términos

- **Inventario:** Conjunto de bienes, insumos y productos terminados que una empresa mantiene almacenados con el fin de garantizar la continuidad de sus operaciones y atender la demanda futura. Incluye materias primas, productos en proceso y productos terminados listos para su comercialización.
- **Gestión de inventarios:** Proceso administrativo que busca mantener un equilibrio entre la disponibilidad de productos y los costos asociados al almacenamiento. Su

objetivo es evitar tanto el desabastecimiento como el sobreabastecimiento, optimizando los recursos financieros y logísticos de la empresa.

- **EOQ (Economic Order Quantity):** Modelo clásico de gestión de inventarios que calcula la cantidad óptima de pedido que minimiza los costos totales de inventario, considerando tanto los costos de pedido como los de almacenamiento.
- **MRP (Material Requirements Planning):** Sistema de planificación que asegura la disponibilidad de materiales en el proceso de producción. Su finalidad es determinar qué insumos se necesitan, en qué cantidad y en qué momento, a partir de la demanda prevista de productos terminados.
- **JIT (Just in Time):** Filosofía de gestión de inventarios que busca reducir al mínimo los niveles de stock, produciendo y entregando únicamente lo necesario, en la cantidad y en el momento exacto en que se requiere.
- **ERP (Enterprise Resource Planning):** Sistema de planificación de recursos empresariales que integra procesos clave de una organización —finanzas, compras, producción, ventas y logística— en un solo entorno digital. En el ámbito de inventarios, permite controlar existencias, automatizar pedidos y mejorar la trazabilidad de los productos.
- **Microsoft Dynamics 365:** Plataforma de gestión empresarial desarrollada por Microsoft que combina ERP y CRM en un entorno modular y basado en la nube. En la gestión de inventarios, permite integrar datos en tiempo real de ventas, compras y producción, automatizar procesos logísticos y garantizar trazabilidad, aunque requiere complementarse con herramientas predictivas externas.

- **Machine Learning:** Rama de la inteligencia artificial que desarrolla algoritmos capaces de aprender a partir de datos históricos y actuales para realizar predicciones o tomar decisiones sin programación explícita. En la gestión de inventarios, se aplica para anticipar la demanda y optimizar los niveles de stock.
- **Sistema predictivo:** Conjunto de herramientas analíticas que, utilizando algoritmos de Machine Learning y datos históricos, permite anticipar escenarios futuros. En el caso de inventarios, facilita la detección temprana de riesgos de desabastecimiento o sobreabastecimiento.
- **Cadena de suministro:** Red integrada de procesos, recursos y actores involucrados en el flujo de bienes y servicios, desde la adquisición de materias primas hasta la entrega final al cliente. Una gestión eficiente de la cadena de suministro asegura disponibilidad de productos, reducción de costos y satisfacción del consumidor final.

2.4. Resumen ejecutivo

Título: Propuesta de implementación de un sistema predictivo basado en machine learning para la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025. **Procedencia:** Tesis de bachiller por San Ignacio de Loyola Escuela ISIL. **Objetivo:** Conocer la factibilidad de implementar un sistema predictivo basado en Machine Learning para la gestión de inventarios en Home Market Foods, evaluando su potencial para reducir costos por sobreabastecimiento, prevenir desabastecimientos críticos y mejorar la eficiencia operativa de la empresa. **Metodología:** La investigación se plantea bajo un enfoque cualitativo-descriptivo y

aplicado. Se realizarán entrevistas semiestructuradas con colaboradores estratégicos y se analizarán los registros históricos de inventarios y ventas con el fin de determinar la factibilidad del modelo predictivo, considerando factores estacionales, patrones de consumo y fluctuaciones de la demanda. **Resultados:** Se espera evidenciar que la implementación de un sistema predictivo resulta viable y que puede contribuir a optimizar la disponibilidad de productos, reducir costos logísticos y aumentar la capacidad de respuesta frente a cambios en la demanda. Asimismo, se proyecta que la propuesta tenga un carácter escalable, de modo que pueda adaptarse tanto a otras áreas de la empresa como a diferentes industrias con desafíos similares de inventario.

2.5. Características técnicas o atributos del proyecto

Tabla 1

Sistema predictivo basado en machine learning para la toma de decisiones en la gestión de inventarios

Atributo	Descripción
Precisión	El sistema predictivo busca alcanzar un alto nivel de exactitud en la estimación de la demanda, reduciendo errores comunes en los métodos tradicionales de proyección de inventarios.
Rapidez	La propuesta permitirá generar predicciones de inventario y reportes de consumo en menor tiempo, gracias a la automatización y al procesamiento de datos en el ERP integrado con Machine Learning.
Confiabilidad	Los resultados obtenidos del modelo serán consistentes y replicables bajo diferentes escenarios, lo que asegura la estabilidad de la herramienta como soporte a la toma de decisiones.
Escalabilidad	El sistema puede adaptarse al crecimiento de la empresa, integrando más líneas de productos, plantas de producción o unidades de negocio sin perder eficiencia en el procesamiento de datos.

Fuente: Elaboración propia

2.6. Análisis comparativo de atributos, características, mejoras o novedades tecnológicas

Tabla 2

Gestión de inventarios

Atributo	MRP en Dynamics 365 (situación actual)	Propuesta de implementación (ERP + Machine learning)
Precisión	Calcula requerimientos de materiales en base a demanda planificada y pedidos históricos, pero no anticipa variaciones abruptas en la demanda.	Algoritmos de Machine Learning (Random Forest, ARIMA, redes neuronales) mejoran la exactitud de pronósticos al considerar patrones estacionales, tendencias y datos históricos complejos.
Rapidez	Requiere ejecución de procesos de planeación periódicos; los cálculos son rápidos, pero los ajustes dependen de intervención manual.	Generación automática de pronósticos en menor tiempo, con reportes dinámicos y alertas en tiempo real integradas al ERP.
Confiabilidad	Resultados confiables en escenarios estables, pero sensibles a cambios en la demanda y a errores en los registros.	Resultados adaptativos que se ajustan al ingreso de nuevos datos, manteniendo consistencia en contextos variables.
Escalabilidad	Permite gestionar más productos, pero la capacidad predictiva no se expande a medida que crece la complejidad de la operación.	Puede procesar grandes volúmenes de datos, nuevas líneas de productos y mayor cobertura de mercado sin perder eficiencia.

Fuente: Elaboración propia.

2.7. Objetivo general y específicos: propósito del proyecto

2.7.1. Objetivo general

Evaluar la viabilidad de implementar un sistema predictivo basado en Machine Learning que contribuya a optimizar la gestión de inventarios en la empresa Home Market Foods, Estados Unidos, 2025.

2.7.2. Objetivos específicos

- Analizar los factores técnicos y organizacionales que influyen en la viabilidad de implementar un sistema predictivo basado en Machine Learning para mejorar la disponibilidad de productos.
- Evaluar las condiciones operativas y tecnológicas que permitirían que un sistema predictivo basado en Machine Learning optimice los tiempos de reabastecimiento.
- Determinar los aspectos económicos y logísticos que influyen en la viabilidad de implementar un sistema predictivo basado en Machine Learning para reducir los costos asociados al abastecimiento.

2.8. Componente del proyecto

El proyecto se organiza en cuatro componentes principales que permiten estructurar el análisis de viabilidad:

- **Componente tecnológico:** comprende la exploración de herramientas de Machine Learning y su integración teórica con el ERP corporativo Microsoft Dynamics 365.
- **Componente metodológico:** abarca la definición del enfoque de investigación, el análisis de datos históricos de inventarios y la validación teórica de modelos predictivos aplicables.
- **Componente organizacional:** se centra en la identificación de capacidades y recursos humanos necesarios para la adopción de un sistema predictivo, así como la disposición al cambio en la empresa.

- **Componente estratégico:** orientado a evaluar la alineación de la propuesta con los objetivos de transformación digital, competitividad y sostenibilidad de Home Market Foods.

2.9. Resultados generales: Componente del proyecto

Los resultados generales que se esperan obtener de cada componente se relacionan con el conocimiento de la viabilidad de la propuesta:

- **Componente tecnológico:** se conocerá si la infraestructura actual y el ERP Microsoft Dynamics 365 pueden sostener la incorporación de modelos de Machine Learning.
- **Componente metodológico:** se obtendrá evidencia sobre la aplicabilidad de algoritmos predictivos en la gestión de inventarios, considerando datos históricos y patrones de consumo.
- **Componente organizacional:** se identificará el grado de preparación del personal y las necesidades de capacitación para la eventual adopción de la propuesta.
- **Componente estratégico:** se establecerá si la propuesta de sistema predictivo es coherente con la visión de transformación digital de la empresa y si aporta ventajas competitivas sostenibles.

2.10. Plan de actividades del proyecto

N	Actividades \ Semanas	Agosto				Setiembre				Octubre				Noviembre				Diciembre			
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1	Redacción del resumen y de la sección introductoria.																				

Propuesta de implementación de un sistema predictivo basado en *machine learning* para mejorar la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025



N	Actividades \ Semanas	Agosto				Setiembre				Octubre				Noviembre				Diciembre			
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
2	Formulación y desarrollo del planteamiento del problema, de los objetivos y de las hipótesis de estudio.																				
3	Sistematización de los antecedentes, construcción del marco teórico y definición de los principales conceptos.																				
4	Desarrollo de los antecedentes de investigación, marco teórico y glosario de términos.																				
5	Diseño y descripción de la metodología de investigación.																				
6	Selección y definición de las técnicas e instrumentos para la recolección de datos.																				
7	Caracterización de la población de estudio y determinación de la muestra objetiva.																				
8	Procesamiento, organización y análisis de la información recolectada mediante los instrumentos aplicados.																				
9	Construcción del diagnóstico de la situación actual.																				
10	Desarrollo del análisis y sustento del mercado objetivo.																				
11	Elaboración de las conclusiones del estudio y de las recomendaciones derivadas de los resultados.																				
12	Presentación y defensa del trabajo ante el jurado externo.																				

2.11. Metodología del proyecto

2.11.1. Hipótesis de la investigación

2.11.1.1. Hipótesis general

En esta investigación no se formulan hipótesis, ya que se trata de un estudio descriptivo en el que no se pretende analizar la relación entre variables ni establecer vínculos de causalidad.

2.11.1.2. Hipótesis específicas

En esta investigación no se formulan hipótesis, ya que se trata de un estudio descriptivo en el que no se pretende analizar la relación entre variables ni establecer vínculos de causalidad.

2.11.2. Operacionalización de variables

Variable 1: Sistema predictivo basado en machine learning.

Definición conceptual: Según Géron (2019) los sistemas de machine learning permiten analizar grandes volúmenes de datos históricos para generar modelos predictivos que anticipen comportamientos o eventos futuros, facilitando así la toma de decisiones estratégicas y operativas.

Definición operacional: La variable sistema predictivo basado en machine learning comprende dos dimensiones: Capacidad predictiva (evaluada mediante la percepción sobre la utilidad y confiabilidad del modelo para prever la demanda, con indicadores como el nivel de confianza y conocimiento técnico) y Adopción tecnológica (que considera la viabilidad y preparación organizacional para su implementación, con

indicadores como preparación del personal y compatibilidad con el sistema ERP actual).

Para recolectar información, se utilizarán entrevistas a colaboradores estratégicos, enfocadas en conocer la percepción técnica, operativa y organizacional sobre la viabilidad y utilidad del sistema.

Variable 2: Gestión de inventarios

Definición conceptual: Según Silver et al. (2017), la gestión de inventarios busca mantener la disponibilidad de productos minimizando los costos totales asociados a su mantenimiento.

Definición operacional: La variable gestión de inventarios se divide en tres dimensiones: Disponibilidad (indicadores: frecuencia de faltantes, cumplimiento de pedidos), Tiempos de reabastecimiento (indicadores: tiempo promedio entre solicitud y reposición, eficiencia del flujo logístico), y Costos operativos (indicadores: tipos de costos más frecuentes, percepción del ahorro potencial con modelos predictivos). La medición se realizará mediante entrevistas a personal con funciones estratégicas en las áreas de logística, compras y planificación. Las preguntas están orientadas a explorar la percepción de los entrevistados sobre los principales problemas actuales en la gestión de inventarios y el impacto potencial que podría tener la implementación de un sistema predictivo en su mejora.

2.11.3. Enfoque de investigación

El enfoque de investigación es cualitativo, ya que se busca comprender en profundidad las percepciones, experiencias y valoraciones de los colaboradores estratégicos respecto a la viabilidad e impacto de implementar un sistema predictivo

basado en machine learning en la gestión de inventarios. Se privilegiará la recolección de datos a través de entrevistas semiestructuradas, permitiendo explorar el fenómeno en su contexto real. Según Hernández y Mendoza (2023), el enfoque cualitativo se orienta al estudio interpretativo de realidades complejas, permitiendo generar conocimientos a partir del análisis de discursos, conductas y significados compartidos por los actores involucrados.

2.11.4. Tipo de investigación

El estudio se clasifica como aplicado porque, de acuerdo con Ñaupas Paitán et al. (2023), cumple una función interventiva al dar respuesta a necesidades y dificultades previamente identificadas en la empresa Home Market Foods específicamente relacionados con la optimización de la gestión de inventarios a través de la propuesta de un sistema predictivo basado en machine learning

2.11.5. Diseño de investigación

El diseño de la investigación es no experimental de tipo transversal, ya que no se interviene ni manipula ninguna de las variables analizadas y la información se recoge en un único momento del tiempo (Hernández & Mendoza, 2023), correspondiente al año 2025.

2.11.6. Nivel de investigación

El nivel de la investigación es descriptivo, dado que se recopilaban datos mediante instrumentos orientados a caracterizar las variables de implementación de sistema predictivo basado en machine learning y gestión de inventarios y precisar sus atributos,

particularidades, dimensiones, propiedades y componentes, de acuerdo con lo señalado por Ñaupas Paitán et al. (2023).

2.11.7. Población

La población de estudio está conformada por los colaboradores vinculados a las operaciones de inventario de la empresa Home Market Foods, ubicada en Norwood, Massachusetts, Estados Unidos. También incluye a los registros históricos del sistema ERP de la empresa, Microsoft Dynamics 365 (D365), el cual fue implementado en junio de 2024.

2.11.8. Muestreo y muestra

La muestra estará conformada por 4 colaboradores con rol estratégico en las áreas vinculadas a la gestión de inventarios, como logística, compras o planificación, en la empresa Home Market Foods. Se seleccionarán mediante un muestreo no probabilístico por conveniencia, considerando su experiencia, conocimiento del proceso y participación directa en la toma de decisiones relacionadas con el abastecimiento y control de inventarios.

2.11.9. Técnicas e instrumentos de recolección de datos

2.11.9.1. Técnicas de recolección de datos

Mejía (2005) señala que las técnicas de acopio de información permiten recopilar, observar o medir variables de estudio con el propósito de obtener evidencia empírica que sustente los objetivos de la investigación. En el presente proyecto, la técnica empleada fue la entrevista semiestructurada, adecuada para estudios de tipo cualitativo orientados a comprender percepciones y experiencias en contextos organizacionales reales.

Esta técnica se aplicó de forma individual a los colaboradores estratégicos de la empresa Home Market Foods, quienes desempeñan funciones vinculadas con la gestión de inventarios, la planificación de abastecimiento y la operación logística. El propósito fue conocer su percepción respecto a la viabilidad de implementar un sistema predictivo basado en Machine Learning en el contexto operativo actual de la empresa. Las entrevistas se realizaron mediante videollamadas a través de la plataforma Microsoft Teams, permitiendo recoger testimonios y comentarios en profundidad sobre temas como la capacidad predictiva, la adopción tecnológica, la disponibilidad de productos, los tiempos de reabastecimiento y los costos operativos.

La información obtenida a través de esta técnica permitió identificar barreras organizacionales, capacidades existentes y expectativas del personal sobre los beneficios potenciales de la propuesta, aportando datos cualitativos esenciales para el análisis de viabilidad del proyecto

2.11.9.2. Instrumentos de recolección de datos

Para esta investigación se trabajó con una guía de entrevista semiestructurada, armada directamente a partir de las variables y dimensiones definidas en la matriz de operacionalización. La idea fue tener una ruta clara al momento de entrevistar: seguir un orden lógico, no perder el hilo y, sobre todo, asegurar que cada pregunta realmente aporte a los objetivos del estudio.

La guía incluyó 10 preguntas abiertas y se organizó en dos bloques. El primero se enfocó en la variable “Sistema predictivo basado en Machine Learning”, cubriendo capacidad predictiva y adopción tecnológica. El segundo bloque se centró en “Gestión de

inventarios”, aterrizado en disponibilidad, tiempos de reabastecimiento y costos operativos. Con ese esquema se buscó recoger lo que los participantes piensan y han vivido en la práctica, además de sus expectativas frente a la propuesta tecnológica.

Las entrevistas se grabaron con consentimiento informado y luego se transcribieron para analizarlas con codificación temática. A partir de ese trabajo se fueron identificando patrones repetidos y categorías que aparecían de manera natural, especialmente vinculadas a la viabilidad técnica, organizacional y económica de implementar el sistema predictivo. Finalmente, la información se ordenó en matrices cualitativas y gráficos de relaciones, lo que ayudó a profundizar la interpretación del fenómeno estudiado.

2.11.10. Validez y confiabilidad

2.11.10.1. Validez del instrumento

Se utilizó la validación mediante juicio de expertos, recurriendo a la evaluación de un especialista en metodología de la investigación, quien revisó el cuestionario considerando criterios como claridad, objetividad, actualidad, organización, suficiencia, intencionalidad, consistencia, coherencia, enfoque metodológico y pertinencia (véase ficha de validación).

Los resultados obtenidos del juicio de expertos se contrastaron con los valores y niveles de validez establecidos en la tabla 3.

Tabla 3

Niveles y valores de validez

Crterios	Niveles	Valores
- Claridad	Deficiente	0-20%
- Objetividad		
- Actualidad	Regular	21-40%
- Organización		
- Suficiencia	Buena	41-60%
- Intencionalidad		
- Consistencia	Muy Buena	61-80%
- Coherencia		
- Metodología	Excelente	81-100%
- Pertinencia		

Fuente. Elaboración propia.

2.11.10.2. Confiabilidad de la investigación

Debido a que la presente investigación es de enfoque cualitativo y no emplea instrumentos de medición estadística, no se aplica el análisis de confiabilidad tradicional.

III. Estimación del costo del proyecto

3.1. Estimación de los costos necesarios para la implementación

La estimación de costos del proyecto se realizó considerando los recursos humanos, bienes y servicios necesarios para la elaboración del estudio de viabilidad de la propuesta de implementación de un sistema predictivo basado en Machine Learning en la gestión de inventarios de la empresa Home Market Foods.

La inversión estimada cubre los gastos relacionados con la contratación de personal especializado, adquisición de equipos tecnológicos, materiales de apoyo y licencias de

software requeridas para el análisis y procesamiento de datos. Asimismo, se incluyen los servicios complementarios necesarios para garantizar la continuidad operativa durante la ejecución del proyecto, como conexión a internet de alta velocidad y acceso a herramientas colaborativas y de inteligencia artificial.

La siguiente tabla detalla los costos estimados según la naturaleza del gasto:

Tabla 4

Estimación de costos necesarios para el desarrollo de la investigación

Naturaleza del gasto	Descripción	Cantidad	Precio Unitario	Precio Total
Personal				
	Profesional altamente calificado	12 meses	S/. 200.00	S/. 2,400.00
Bienes				
	Laptop Asus	1 unidad	S/. 2,990.00	S/. 2,990.00
	Teléfono Móvil Apple	1 unidad	S/. 1,330.00	S/. 1,330.00
	Disco Duro SSD – 2TB	1 unidad	S/. 1,230.00	S/. 1,230.00
	Material Bibliográfico	2 unidades	S/. 126.07	S/. 252.15
Servicios				
	Internet Plan WIN – 1000Mbps	12 meses	S/. 160.00	S/. 1,920.00
	Licencia Microsoft Office 365	12 meses	S/. 25.75	S/. 308.99
Resumen				
	Personal			S/. 2,400.00
	Bienes			S/. 5,802.15
	Servicios			S/. 3,040.19
Total				S/. 10,431.14

Nota: Elaboración Propia

Interpretación: Como se observa en la Tabla 5, la mayor inversión se concentra en los rubros de bienes tecnológicos y personal calificado, indispensables para el desarrollo del análisis técnico y metodológico del proyecto. Los bienes representan las herramientas

físicas y bibliográficas requeridas para ejecutar simulaciones, pruebas y procesamiento de información.

Por su parte, los servicios comprenden suscripciones, licencias de software y recursos digitales que facilitan el modelado de datos, la colaboración remota y el uso de modelos predictivos. El monto total proyectado llega a S/. 11,242.34, monto que refleja una inversión proporcional al alcance del estudio y necesaria para garantizar resultados confiables, replicables y metodológicamente consistentes.

IV. Análisis de resultados descriptivos

4.1. Análisis de datos cualitativos

Categoría: Capacidad predictiva

Pregunta 1: ¿Qué importancia tiene para su área poder anticipar la demanda futura de productos? ¿por qué?

Tabla 5

Subcategoría: Nivel de confianza en las predicciones

Códigos	Citas de entrevista
Anticipación de la demanda	<ul style="list-style-type: none"> – "Anticipar la demanda nos permite planificar compras, producción y almacenamiento con mucha más precisión." [MC45-1] – "Es clave. Si ya sé qué piezas voy a necesitar, no pierdo tiempo esperando que lleguen." [FS67-1] – "En compras vivimos de lo bien que podamos anticipar lo que viene." [KG44-1] – "anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1]
Planificación	<ul style="list-style-type: none"> – "Anticipar la demanda nos permite planificar compras, producción y almacenamiento con mucha más precisión." [MC45-1] – "Desde el punto de vista del ERP y la planificación, anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1]

Códigos	Citas de entrevista
Rotura de stock	<ul style="list-style-type: none"> – "los quiebres son más comunes, sobre todo cuando la demanda supera lo previsto o hay retrasos desde los proveedores." [MC45-5] – "A veces seguido. Sobre todo con repuestos específicos, que no se usan mucho, pero cuando se malogra algo y no hay, quedamos mal." [FS67-5] – "equilibrar el exceso y la escasez de existencias." [KG44-5] – "La mayoría de los quiebres de stock se deben a problemas de tiempo: órdenes que no se liberan a tiempo o demanda que cambia más rápido de lo que el MRP puede reaccionar." [VL31-6]

Fuente: Elaboración propia.

Pregunta 2: ¿Considera útil predecir la demanda en base a datos históricos? ¿por qué?

Tabla 6

Subcategoría: Conocimiento sobre la utilidad del modelo

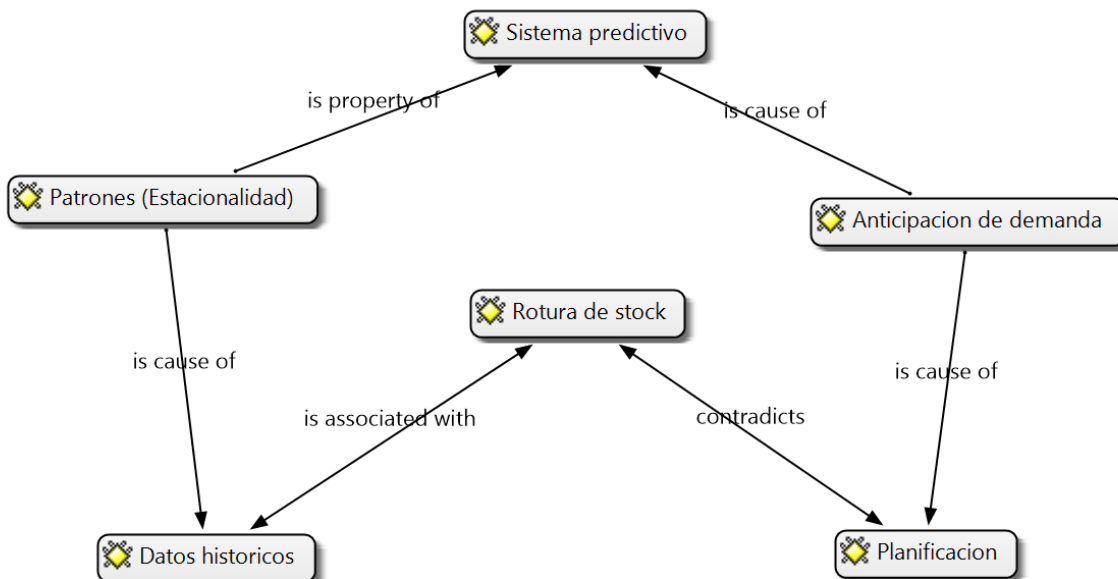
Códigos	Citas de entrevista
Datos históricos	<ul style="list-style-type: none"> – "Sí, totalmente. Los datos históricos reflejan patrones que muchas veces se repiten, como estacionalidad, promociones o comportamiento de clientes clave." [MC45-2] – "Sí, claro. Si ya sabemos qué partes se malogran más seguido o en qué temporada hay más chamba, eso ayuda un montón." [FS67-2] – "Sí, absolutamente, aunque con precaución. Los datos históricos cuentan una historia, pero no toda." [KG44-2] – "Definitivamente. Los datos históricos muestran los patrones: estacionalidad, tendencias de clientes, comportamientos que no se pueden medir de otra forma." [VL31-2]
Patrones	<ul style="list-style-type: none"> – "Los datos históricos reflejan patrones que muchas veces se repiten, como estacionalidad, promociones o comportamiento de clientes clave." [MC45-2] – "Si ya sabemos qué partes se malogran más seguido o en qué temporada hay más chamba, eso ayuda un montón." [FS67-2] – "Si combinamos historia con señales actuales — estacionalidad, promociones, comportamiento del

Códigos	Citas de entrevista
	<p>cliente— el modelo puede ser muy efectivo." [KG44-2]</p> <ul style="list-style-type: none"> – "Los datos históricos muestran los patrones: estacionalidad, tendencias de clientes, comportamientos que no se pueden medir de otra forma." [VL31-2]
Sistema predictivo	<ul style="list-style-type: none"> – "nos falta capacitación específica en modelos predictivos." [MC45-3] – "Si el modelo funciona, los quiebres de stock se reducirían, porque muchas veces estos ocurren cuando el pronóstico llega tarde o hay fallas de comunicación." [KG44-6] – "El desafío sería conectar una capa predictiva sin duplicar la lógica existente y enseñar a los usuarios cómo interpretar correctamente los resultados." [VL31-3] – "Un modelo predictivo podría detectar esas variaciones con anticipación." [VL31-6]

Fuente: Elaboración propia.

Figura 5

Red Capacidad Predictiva



Fuente: Elaboración propia.

Interpretación: Anticipar la demanda, es importante en la planificación, sin ella o sin un correcto desarrollo, se vuelve reactiva y tarde o temprano aparecen quiebres de stock. Pero esa anticipación no sale “por intuición”: depende de tener históricos bien trabajados, sin ruido, porque ahí es donde se pueden ver los patrones reales. En la práctica, mientras más limpia y analizada esté la data pasada, más confiable termina siendo el sistema predictivo y mejor se sostiene la precisión del pronóstico.

Categoría: Adopción tecnológica

Pregunta 3: ¿Qué tan preparado cree que está su equipo o área para adoptar una solución tecnológica como un sistema predictivo? ¿por qué?

Tabla 7

Subcategoría: Nivel de preparación del equipo

Códigos	Citas de entrevista
Sistema predictivo	<ul style="list-style-type: none"> – "nos falta capacitación específica en modelos predictivos." [MC45-3] – "Si el modelo funciona, los quiebres de stock se reducirían, porque muchas veces estos ocurren cuando el pronóstico llega tarde o hay fallas de comunicación." [KG44-6] – "El desafío sería conectar una capa predictiva sin duplicar la lógica existente y enseñar a los usuarios cómo interpretar correctamente los resultados." [VL31-3] – "Un modelo predictivo podría detectar esas variaciones con anticipación." [VL31-6]
Preparación / Capacitación	<ul style="list-style-type: none"> – "nos falta capacitación específica en modelos predictivos." [MC45-3] – "si alguien nos capacita bien y vemos que funciona, yo sí creo que nos adaptamos." [FS67-3] – "tomará algo de acompañamiento." [KG44-3] – "enseñar a los usuarios cómo interpretar correctamente los resultados." [VL31-3]
Cultura de datos	<ul style="list-style-type: none"> – "la cultura de datos existe." [KG44-3]

Códigos	Citas de entrevista
Confianza	<ul style="list-style-type: none"> – "Culturalmente, algunos usuarios aún dependen de reportes estáticos o validaciones en Excel." [VL31-4] – "cierto temor a perder el control sobre las decisiones si 'una máquina decide'." [MC45-3] – "las personas deben creer en el sistema antes de actuar." [KG44-3] – "generar confianza." [KG44-4] – "La adopción dependerá de que las predicciones se alineen con la realidad operativa." [VL31-4]

Fuente: Elaboración propia.

Pregunta 4: ¿Qué obstáculos técnicos o de cultura digital ve en la implementación? ¿por qué?

Tabla 8

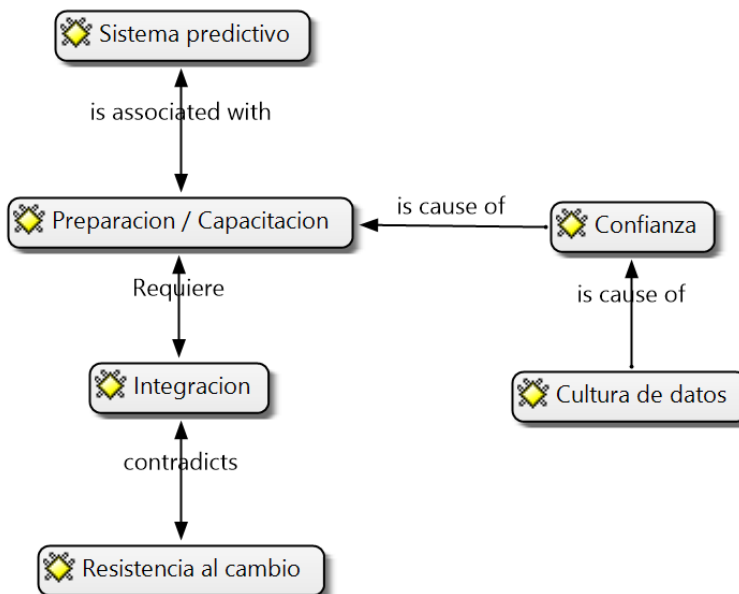
Subcategoría: Grado de compatibilidad con procesos actuales

Códigos	Citas de entrevista
Integración	<ul style="list-style-type: none"> – "falta de integración entre áreas." [MC45-4] – "no todos tienen costumbre de registrar bien las cosas." [FS67-4] – "la capa de integración podría ser complicada." [KG44-4] – "la integración y las tasas de actualización son el principal problema." [VL31-4]
Resistencia al cambio	<ul style="list-style-type: none"> – "resistencia natural al cambio por parte de algunos mandos medios que prefieren 'la forma tradicional' de operar." [MC45-4] – "no les gusta estar metiéndose en sistemas." [FS67-4] – "mentalidad de 'ver para creer'." [KG44-4] – "Culturalmente, algunos usuarios aún dependen de reportes estáticos o validaciones en Excel." [VL31-4]
Cultura de datos	<ul style="list-style-type: none"> – "la cultura de datos existe." [KG44-3] – "Culturalmente, algunos usuarios aún dependen de reportes estáticos o validaciones en Excel." [VL31-4]

Fuente: Elaboración propia.

Figura 6

Red Adopción Tecnológica



Fuente: Elaboración propia.

Interpretación: La implementación de un sistema predictivo enfrenta obstáculos tanto técnicos como humanos. Existe una resistencia al cambio y baja confianza en los sistemas, agravada por problemas de integración de datos. Superar esto requiere una sólida preparación y capacitación para fomentar una cultura de datos que permita la adopción efectiva de la nueva tecnología.

Categoría: Disponibilidad

Pregunta 5: ¿Con que frecuencia enfrentan problemas de falta de productos de inventario? ¿por qué?

Tabla 9

Subcategoría Frecuencia de faltantes

Códigos	Citas de entrevista
Rotura de stock	– "los quiebres son más comunes, sobre todo cuando la demanda supera lo previsto o hay retrasos desde los proveedores." [MC45-5]

Códigos	Citas de entrevista
	<ul style="list-style-type: none"> - "A veces seguido. Sobre todo con repuestos específicos, que no se usan mucho, pero cuando se malogra algo y no hay, quedamos mal." [FS67-5] - "equilibrar el exceso y la escasez de existencias." [KG44-5] - "La mayoría de los quiebres de stock se deben a problemas de tiempo: órdenes que no se liberan a tiempo o demanda que cambia más rápido de lo que el MRP puede reaccionar." [VL31-6]
Rotación	<ul style="list-style-type: none"> - "productos de alta rotación o con estacionalidad marcada." [MC45-5] - "productos que se quedan. A veces compras repuestos y no se usan en meses, y eso es plata amarrada." [FS67-9] - "materiales de baja rotación." [KG44-9] - "insumos que caducan antes de usarse." [VL31-9]
Visibilidad	<ul style="list-style-type: none"> - "visibilidad limitada de la demanda real." [MC45-1] - "visibilidad de datos." [KG44-8] - "datos casi en tiempo real." [VL31-4]

Fuente: Elaboración propia.

Pregunta 6: ¿Considera que anticipar la demanda ayudaría a reducir los casos de desabastecimiento? ¿por qué?

Tabla 10

Subcategoría: Impacto en el cumplimiento de pedidos

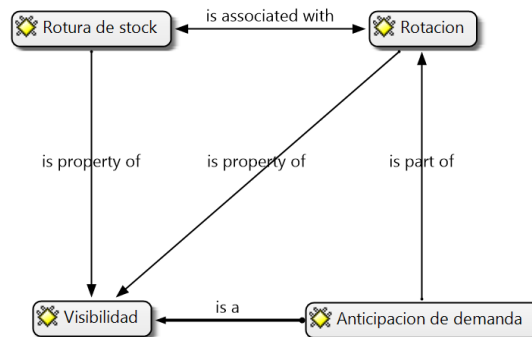
Códigos	Citas de entrevista
Anticipación de la demanda	<ul style="list-style-type: none"> - "Anticipar la demanda nos permite planificar compras, producción y almacenamiento con mucha más precisión." [MC45-1] - "Es clave. Si ya sé qué piezas voy a necesitar, no pierdo tiempo esperando que lleguen." [FS67-1] - "En compras vivimos de lo bien que podamos anticipar lo que viene." [KG44-1] - "anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1]
Rotura de stock	<ul style="list-style-type: none"> - "los quiebres son más comunes, sobre todo cuando la demanda supera lo previsto o hay retrasos desde los proveedores." [MC45-5]

Códigos	Citas de entrevista
	<ul style="list-style-type: none"> - "A veces seguido. Sobre todo con repuestos específicos, que no se usan mucho, pero cuando se malogra algo y no hay, quedamos mal." [FS67-5] - "equilibrar el exceso y la escasez de existencias." [KG44-5] - "La mayoría de los quiebres de stock se deben a problemas de tiempo: órdenes que no se liberan a tiempo o demanda que cambia más rápido de lo que el MRP puede reaccionar." [VL31-6]
Visibilidad	<ul style="list-style-type: none"> - "visibilidad limitada de la demanda real." [MC45-1] - "visibilidad de datos." [KG44-8] - "datos casi en tiempo real." [VL31-4]

Fuente: Elaboración propia.

Figura 7

Red Disponibilidad



Fuente: Elaboración propia.

Interpretación: Los desabastecimientos son frecuentes, especialmente en productos con rotación estacional o baja. La causa principal es la falta de visibilidad de la demanda futura. Las entrevistas concluyen que la anticipación de la demanda es la solución clave para mejorar la disponibilidad, ya que proporciona la visibilidad necesaria para actuar de manera proactiva y evitar quiebres.

Categoría: Tiempos de reabastecimiento

Pregunta 7: ¿Cómo describiría la eficiencia actual del proceso de reabastecimiento?

¿por qué?

Tabla 11

Subcategoría: Tiempo promedio desde la alerta hacia la reposición.

Códigos	Citas de entrevista
Eficiencia	<ul style="list-style-type: none"> – "aceptable, pero perfectible." [MC45-7] – "Regular, tirando a lento." [FS67-7] – "La eficiencia existe en las herramientas, pero no siempre en el flujo de trabajo." [KG44-7] – "está mejorando, pero sigue siendo reactivo." [VL31-7]
MRP	<ul style="list-style-type: none"> – "A veces un artículo no aparece en el reporte MRP, o los filtros no lo muestran correctamente." [KG44-8] – "anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1] – "Cuando no se confía en el MRP, se retrasan o modifican los planes." [VL31-7] – "la validación de datos o la regeneración del MRP. Este proceso toma entre 1.5 y 2 horas." [VL31-8]
Aprobaciones / Validación	<ul style="list-style-type: none"> – "validación de pedidos y aprobaciones internas." [MC45-8] – "internamente, si no se pide a tiempo, se pierde tiempo." [FS67-8] – "aprobaciones pueden ser lentas porque se quiere revisar todo antes de aprobar." [KG44-8] – "validación de datos o la regeneración del MRP." [VL31-8]

Fuente: Elaboración propia.

Pregunta 8: ¿Qué parte del proceso genera más demoras? ¿por qué?

Tabla 12

Subcategoría: Flujo logístico actual

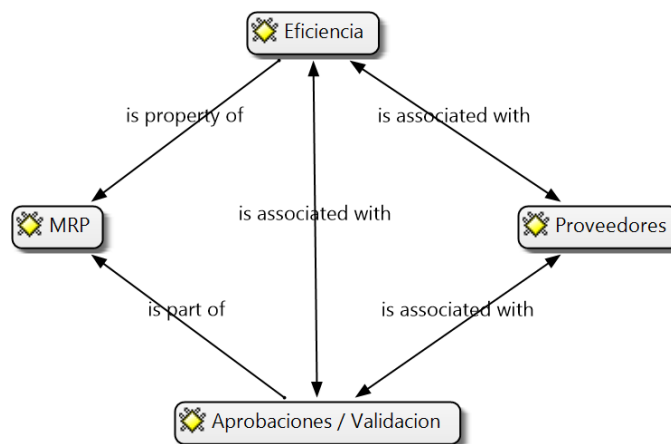
Códigos	Citas de entrevista
Aprobaciones / Validación	<ul style="list-style-type: none"> – "validación de pedidos y aprobaciones internas." [MC45-8] – "internamente, si no se pide a tiempo, se pierde tiempo." [FS67-8] – "aprobaciones pueden ser lentas porque se quiere revisar todo antes de aprobar." [KG44-8] – "validación de datos o la regeneración del MRP." [VL31-8]

Códigos	Citas de entrevista
MRP	<ul style="list-style-type: none"> – "A veces un artículo no aparece en el reporte MRP, o los filtros no lo muestran correctamente." [KG44-8] – "anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1] – "Cuando no se confía en el MRP, se retrasan o modifican los planes." [VL31-7] – "la validación de datos o la regeneración del MRP. Este proceso toma entre 1.5 y 2 horas." [VL31-8]
Proveedores	<ul style="list-style-type: none"> – "retrasos desde los proveedores." [MC45-5] – "tiempos de respuesta de proveedores." [MC45-8] – "proveedor, algunos son puntuales y otros no." [FS67-8] – "capacidad de los proveedores." [VL31-5]

Fuente: Elaboración propia.

Figura 8

Red Tiempos de reabastecimiento



Fuente: Elaboración propia.

Interpretación: La eficiencia del reabastecimiento es calificada como reactiva. Las mayores demoras se generan en las aprobaciones y validación manual de datos, y en la lenta respuesta de los proveedores. El sistema MRP, aunque está presente, no se aprovecha totalmente, ya que sus resultados son frecuentemente cuestionados y revalidados, lo que ralentiza todo el proceso.

Categoría: Costos operativos

Pregunta 9: ¿Qué tipos de costos asociados a la gestión de inventarios son más problemáticos en su experiencia? ¿por qué?

Tabla 13

Subcategoría: Tipos de costos asociados al inventario

Códigos	Citas de entrevista
Exceso de inventario	<ul style="list-style-type: none"> – "validación de pedidos y aprobaciones internas." [MC45-8] – "internamente, si no se pide a tiempo, se pierde tiempo." [FS67-8] – "aprobaciones pueden ser lentas porque se quiere revisar todo antes de aprobar." [KG44-8] – "validación de datos o la regeneración del MRP." [VL31-8]
Costos ocultos	<ul style="list-style-type: none"> – "A veces un artículo no aparece en el reporte MRP, o los filtros no lo muestran correctamente." [KG44-8] – "anticipar la demanda ayuda a estabilizar todo el proceso MRP." [VL31-1] – "Cuando no se confía en el MRP, se retrasan o modifican los planes." [VL31-7] – "la validación de datos o la regeneración del MRP. Este proceso toma entre 1.5 y 2 horas." [VL31-8]
Rotación	<ul style="list-style-type: none"> – "retrasos desde los proveedores." [MC45-5] – "tiempos de respuesta de proveedores." [MC45-8] – "proveedor, algunos son puntuales y otros no." [FS67-8] – "capacidad de los proveedores." [VL31-5]

Fuente: Elaboración propia.

Pregunta 10: ¿Qué impacto financiero cree que tendría un sistema que optimice los niveles de inventario? ¿por qué?

Tabla 14

Subcategoría: Potencial ahorro con predicción

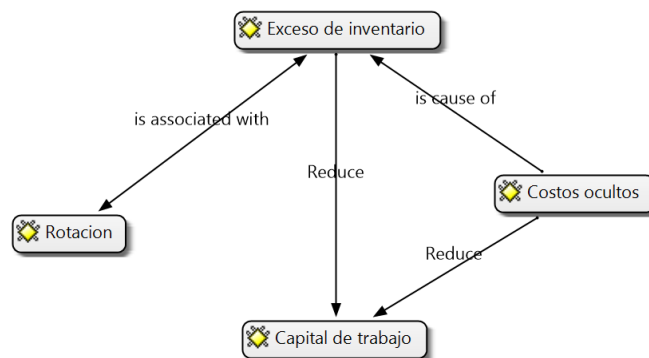
Códigos	Citas de entrevista
Capital de trabajo	<ul style="list-style-type: none"> – "liberaría capital para otras áreas del negocio." [MC45-10]

Códigos	Citas de entrevista
	<ul style="list-style-type: none"> - "ahorrar un montón, porque compraríamos solo lo justo y evitaríamos pérdidas por productos guardados que ya no sirven." [FS67-10] - "libera capital y reduce el desperdicio." [KG44-10] - "libera capital de trabajo." [VL31-10]
Exceso de inventario	<ul style="list-style-type: none"> - "exceso de inventario, especialmente en productos con fecha de vencimiento o baja rotación." [MC45-9] - "productos que se quedan. A veces compras repuestos y no se usan en meses, y eso es plata amarrada." [FS67-9] - "exceso de existencias." [KG44-9] - "exceso de inventario." [VL31-9]
Costos ocultos	<ul style="list-style-type: none"> - "costos ocultos de almacenamiento (espacio, personal, energía)." [MC45-9] - "plata amarrada. Y los repuestos viejos ya nadie los quiere." [FS67-9] - "costos de mantenimiento o de tenencia, especialmente en materiales de baja rotación. También la obsolescencia." [KG44-9] - "costos de tenencia son importantes, pero el más oculto es la ineficiencia." [VL31-9]

Fuente: Elaboración propia.

Figura 9

Red Costos Operativos



Fuente: Elaboración propia.

Interpretación: Tanto el exceso de inventario como la baja rotación tienen impacto en los costos ocultos. Esto limita el capital de trabajo disponible y, por ende, limita la liquidez

de la empresa. Optimizar estos niveles de inventario mediante una mejor prevision liberaria capital y finalmente impactando positivamente en los resultados financieros.

V. Plan de implementación y viabilidad

5.1. Análisis del mercado

En Home Market Foods, implementar un sistema predictivo no es un “proyecto de innovación”, es una respuesta a cómo se compite en este negocio: rapidez y eficiencia operativa. En alimentos congelados la demanda se mueve por estacionalidad y por cambios de consumo, y eso obliga a reaccionar mejor para no terminar con desperdicio en perecibles y, al mismo tiempo, no inflar el costo logístico.

En paralelo, la cadena de suministro se está digitalizando de verdad. La analítica avanzada y el Machine Learning dejaron de ser un extra y pasaron a ser la herramienta que usan las empresas que quieren operar con menos improvisación. Pero el punto no es solo “tener un modelo”, sino que el modelo se conecte con el proceso y con la gente que lo usa. En Home Market Foods eso calza con lo que ya se ve: hay base tecnológica, pero todavía hay espacio para madurar la cultura de datos y la adopción en la operación. Con los modelos tradicionales (EOQ, MRP) se puede ordenar una parte del problema, pero se quedan cortos cuando la demanda es variable y el entorno es más complejo. En cambio, cuando el ML está bien aplicado, baja el error de pronóstico y mejora la disponibilidad; hay experiencias documentadas en industrias exigentes como minería y φapma donde se ve ese efecto en la práctica.

En un mercado alimentario maduro, la diferencia no viene de “inventar algo”, viene de ejecutar mejor. Anticipar demanda y ajustar inventarios reduce riesgos operativos y financieros, y también sostiene la rentabilidad. Por eso la propuesta apunta a mover a la

empresa de un manejo reactivo a uno predictivo, con decisiones más a tiempo y una operación más consistente en el largo plazo.

5.2. Descripción del mercado

El mercado objetivo de la presente propuesta se compone, en primer término, por la propia organización Home Market Foods y, en segundo término, por un conjunto más amplio de actores del sector de alimentos perecibles que comparten problemáticas similares de gestión de inventarios.

Tabla 15

Contexto del mercado

Elementos	Descripción
Sector industrial	Industria de alimentos preparados y congelados, con alta sensibilidad a la calidad, la inocuidad y la continuidad del abastecimiento.
Tipo de productos	Productos cárnicos y alimentos congelados/refrigerados, con vida útil limitada y costos relevantes por mermas, vencimientos y obsolescencia.
Ámbito geográfico	Operaciones principalmente en Estados Unidos, con foco en la planta de Home Market Foods (Norwood, MA), pero con posibilidad de réplica a otras plantas o empresas del sector.
Naturaleza de la demanda	Demanda variable y estacional, sujeta a promociones comerciales y a cambios en las preferencias del consumidor, lo que incrementa la incertidumbre en la planificación de inventarios.
Problemática central de inventarios	Coexistencia de faltantes (quiebres de stock) y excesos de inventario, generando pérdidas de ventas, costos de almacenamiento, inmovilización de capital y riesgo de vencimientos.
Entorno tecnológico	Presencia de un ERP corporativo (Microsoft Dynamics 365) y soluciones de Business Intelligence, pero con uso todavía limitado de analítica predictiva y de modelos avanzados de Machine Learning.
Relevancia estratégica	La optimización de inventarios impacta directamente en la rentabilidad, el nivel de servicio al cliente y la competitividad de la empresa en el mercado de alimentos preparados.

Fuente: Elaboración propia.

La Tabla 15 presenta el contexto del mercado en el que se implementaría el sistema predictivo, detallando características del sector, tipo de productos, comportamiento de la demanda, entorno tecnológico disponible y relevancia estratégica de optimizar la gestión de inventarios en dicho entorno competitivo.

Tabla 16

Clientes potenciales

Elementos	Descripción
Cliente interno principal	Home Market Foods, específicamente las áreas de logística, planificación, compras, operaciones y finanzas, como usuarios directos del sistema predictivo de inventarios.
Usuarios internos indirectos	Productos cárnicos y alimentos congelados/refrigerados, con vida útil limitada y costos relevantes por mermas, vencimientos y obsolescencia.
Empresas del mismo sector	Operaciones principalmente en Estados Unidos, con foco en la planta de Home Market Foods (Norwood, MA), pero con posibilidad de réplica a otras plantas o empresas del sector.
Empresas con ERP similares	Demanda variable y estacional, sujeta a promociones comerciales y a cambios en las preferencias del consumidor, lo que incrementa la incertidumbre en la planificación de inventarios.
Operadores logísticos y 3PL	Coexistencia de faltantes (quiebres de stock) y excesos de inventario, generando pérdidas de ventas, costos de almacenamiento, inmovilización de capital y riesgo de vencimientos.
Consultores y socios tecnológicos	Empresas de consultoría y partners tecnológicos que podrían integrar o adaptar el modelo desarrollado como parte de sus servicios de transformación digital y optimización de la cadena de suministro.

Fuente: Elaboración propia.

La Tabla 16 resume los principales clientes potenciales de la solución, diferenciando entre usuarios internos de Home Market Foods y organizaciones externas del sector alimenticio, operadores logísticos y socios tecnológicos, todos ellos susceptibles de beneficiarse de la analítica predictiva aplicada a la gestión de inventarios.

En conjunto, el análisis del contexto y de los clientes potenciales evidencia una oportunidad clara para desarrollar, validar y escalar la propuesta.

5.3. Diagnostico FODA

El diagnóstico FODA permite evaluar la posición actual de Home Market Foods frente a la implementación de un sistema predictivo de inventarios, identificando factores internos y externos que condicionan su adopción, aprovechamiento y escalamiento dentro de la organización y del sector alimenticio.

El FODA se construyó a partir de los hallazgos cualitativos obtenidos en las entrevistas y del análisis de la situación actual de la gestión de inventarios. Se identificaron fortalezas relacionadas con la infraestructura tecnológica disponible y el conocimiento del negocio; debilidades asociadas a la cultura de datos y la dependencia de procesos manuales; oportunidades vinculadas a la anticipación de la demanda, mejora del servicio y reducción de costos; y amenazas provenientes de la variabilidad del mercado, la complejidad de la cadena de suministro y la posible resistencia al cambio.

Tabla 17

Análisis FODA del sistema predictivo de inventarios

Análisis	Descripción
Fortalezas	<ul style="list-style-type: none">– Existencia de un ERP corporativo (Microsoft Dynamics 365) y herramientas de Business Intelligence que facilitan la integración de datos y la implementación de soluciones analíticas avanzadas.– Conocimiento profundo del negocio y de la dinámica de inventarios por parte de los equipos de logística, planificación, compras y operaciones.– Disponibilidad de históricos de inventarios, ventas y producción que permiten entrenar y validar modelos predictivos con base empírica.

Análisis	Descripción
Oportunidades	<ul style="list-style-type: none"> – Anticipación de la demanda mediante modelos de Machine Learning, reduciendo quiebres de stock y mejorando la planificación de compras y producción. – Mejora del nivel de servicio al cliente, al asegurar mayor continuidad en el abastecimiento y reducir incumplimientos por falta de producto. – Posicionamiento de Home Market Foods como organización innovadora en la gestión de inventarios, generando aprendizajes que pueden escalarse o compartirse con otras unidades o socios.
Debilidades	<ul style="list-style-type: none"> – Cultura de datos aún incipiente, con cierta desconfianza en los reportes del sistema y fuerte hábito de validar la información en hojas de cálculo. – Alta dependencia de procesos manuales y decisiones reactivas en la gestión de inventarios, que limitan el aprovechamiento pleno del ERP y de la analítica disponible. – Limitada estandarización de procedimientos de planificación y reabastecimiento, lo que dificulta la adopción homogénea de un sistema predictivo en todas las áreas.
Amenazas	<ul style="list-style-type: none"> – Variabilidad de la demanda y cambios en el entorno de mercado que pueden afectar la precisión de los modelos si no se actualizan y recalibran de forma continua. – Resistencia al cambio por parte de algunos usuarios clave, que podrían percibir el sistema predictivo como una imposición tecnológica o una amenaza a sus prácticas habituales. – Riesgos asociados a la calidad e integridad de los datos; decisiones basadas en información incompleta o inconsistente pueden afectar la confianza en el sistema y sus resultados.

Fuente: Elaboración propia.

5.4. Propuesta de valor

La implementación de un sistema predictivo de inventarios en Home Market Foods se justifica porque transforma la gestión actual (reactiva y apoyada en validaciones manuales) en un proceso proactivo, basado en datos y alineado con la estrategia de eficiencia operativa y mejora del servicio a los clientes comerciales.

En términos concretos, el sistema permite reducir costos por exceso de inventario y por quiebres de stock. Al anticipar la demanda con mayor precisión, se disminuyen los productos inmovilizados, vencidos o con alta probabilidad de obsolescencia, liberando capital de trabajo y reduciendo gastos de almacenamiento. A la vez, se minimizan los quiebres de stock que hoy generan pérdidas de venta, urgencias operativas y tensiones con cuentas clave.

Asimismo, la solución optimiza los tiempos de reabastecimiento, al entregar señales tempranas sobre cuándo ordenar, en qué cantidades y para qué referencias priorizar capacidad productiva y logística. Esto contribuye a una planificación más estable, menos dependiente de decisiones de última hora y más coherente con las restricciones reales de planta y cadena de suministro.

Por último, el sistema mejora la disponibilidad del producto para los principales clientes B2B de Home Market Foods —como retailers y cadenas de conveniencia (por ejemplo, Walmart, 7-Eleven, Circle K, entre otros)— al reducir faltantes en sus órdenes y dar mayor continuidad al abastecimiento. De este modo, se fortalece la relación comercial, se protege la participación en anaquel y se refuerza la percepción de confiabilidad como proveedor.

5.5. Análisis de beneficios

Según reportes de la empresa, los quiebres de stock generan aproximadamente USD 300 000 semanales en ventas perdidas, es decir, alrededor de USD 15.3 millones anuales, equivalentes a cerca del 3.2 % de las ventas totales (USD 480 millones). La implementación de un sistema predictivo orientado a anticipar la demanda y reducir

dichos quiebres permitiría recuperar una proporción significativa de esa venta perdida anual, mejorando directamente los ingresos y contribuyendo a fortalecer la rentabilidad de Home Market Foods.

5.6. Plan de adopción tecnológica

El plan de adopción tecnológica se plantea como una propuesta gradual que reduzca riesgos y responda directamente a los problemas identificados (quiebres de stock, gestión reactiva, cultura de datos incipiente). No es un plan de ejecución inmediata, sino una hoja de ruta para su futura implementación.

En una primera fase piloto, se seleccionará una familia de productos y un conjunto acotado de usuarios clave (planificación, logística, compras) para probar el sistema predictivo, validar la calidad de los pronósticos y ajustar parámetros técnicos y operativos. Esta fase incluirá un cronograma estimado con hitos de diseño, pruebas y evaluación de resultados.

Luego, en la fase de escalamiento, el sistema se extenderá progresivamente a más categorías de productos y áreas usuarias, utilizando los aprendizajes del piloto. Se contemplan acciones de capacitación continua (talleres prácticos, guías de uso, acompañamiento a “usuarios campeones”) y un plan de gestión del cambio cultural basado en comunicación clara de beneficios, espacios de retroalimentación y seguimiento de indicadores de adopción.

De este modo, la propuesta de adopción tecnológica busca integrar el sistema predictivo en la operación diaria, fortaleciendo la confianza en los datos y la toma de decisiones basada en evidencia.

5.7. Plan de actividades de implementación

Para poner en marcha la propuesta se plantea un conjunto de actividades organizadas de forma secuencial, que abarcan desde la preparación de datos hasta la operación regular del sistema predictivo dentro de Home Market Foods.

En primer lugar, se realizaría la recopilación, depuración y estandarización de datos de inventarios, ventas, órdenes de producción, tiempos de reabastecimiento y ajustes por quiebres o vencimientos. Paralelamente, se definirían los indicadores clave (por ejemplo, fill rate, días de inventario, ventas perdidas estimadas) que permitirán evaluar el impacto del sistema.

A continuación, se desarrollaría el diseño y entrenamiento del modelo de Machine Learning, incluyendo la selección de algoritmos, pruebas comparativas y validación sobre datos históricos. Una vez alcanzado un desempeño aceptable, se trabajaría en la integración técnica con el ERP (Dynamics 365) y con las herramientas de Business Intelligence, para que las predicciones estén disponibles en tableros y reportes de uso cotidiano.

Posteriormente, se implementaría la fase piloto, acompañada de actividades de capacitación a los usuarios clave y sesiones de ajuste funcional (feedback sobre la interpretación de las recomendaciones, frecuencia de actualización, formatos de visualización). Finalmente, se planificaría la fase de despliegue gradual al resto de productos y áreas, junto con un esquema de monitoreo continuo del modelo, revisiones periódicas de desempeño y ajustes necesarios para asegurar la vigencia y utilidad del sistema predictivo en la operación diaria.

5.8. Alianzas estratégicas

Para la implementación de un sistema predictivo de inventarios, Home Market Foods requerirá alianzas estratégicas que complementen sus capacidades internas. En primer lugar, resultan clave las consultoras especializadas en Data Science y Machine Learning, que puedan apoyar en el diseño de modelos, buenas prácticas de MLOps y transferencia de conocimiento al equipo interno.

Asimismo, serán necesarios integradores certificados de Microsoft Dynamics 365, capaces de asegurar una conexión robusta entre el ERP, las fuentes de datos operacionales y las herramientas de analítica (por ejemplo, Power BI), garantizando calidad de datos y fluidez en los flujos de información. Finalmente, los proveedores de plataformas de Machine Learning en la nube, como Azure Machine Learning o AWS SageMaker, aportarán infraestructura escalable, servicios administrados y herramientas para el despliegue y monitoreo de modelos. Estas alianzas permitirán reducir riesgos técnicos, acelerar la adopción y consolidar una solución sostenible en el tiempo.

5.9. Plan de comunicación interna

El plan de comunicación interna buscará mantener informados y comprometidos a los principales stakeholders (gerencia, jefes de área, personal de logística, planificación y TI) durante todo el proceso. Se utilizarán comunicados en la intranet corporativa y boletines electrónicos periódicos para compartir objetivos, avances, hitos y resultados del piloto. Además, se realizarán reuniones de seguimiento mensuales con gerentes y jefes de área, donde se presentarán indicadores clave y se recogerá retroalimentación. Para el personal operativo, se organizarán sesiones breves de actualización y

demostraciones del sistema, reforzando beneficios concretos y resolviendo dudas, a fin de fortalecer la adopción y la confianza en la herramienta.

VI. Conclusiones y recomendaciones

6.1. Conclusiones

6.1.1. Conclusiones generales

La investigación concluye que la implementación de un sistema predictivo basado en Machine Learning para la gestión de inventarios en Home Market Foods resulta viable en términos tecnológicos, organizacionales y estratégicos, siempre que se acompañe de una adecuada gestión de datos, fortalecimiento de la cultura analítica y un plan estructurado de adopción y cambio organizacional.

Este tipo de sistema se perfila como una respuesta pertinente a los principales problemas identificados en la empresa, relacionados con quiebres de stock, tiempos de reabastecimiento reactivos y costos operativos asociados al exceso de inventario y al uso ineficiente del capital de trabajo.

6.1.2. Conclusiones específicas

- En relación con los factores técnicos y organizacionales, se concluye que Home Market Foods dispone de una base tecnológica sólida (ERP corporativo y herramientas de Business Intelligence) y de equipos con conocimiento del negocio; sin embargo, la viabilidad del sistema predictivo depende de superar brechas en calidad de datos, coordinación entre áreas, confianza en los sistemas y madurez de la cultura de datos.

- Respecto a las condiciones operativas y tecnológicas, se concluye que el proceso de reabastecimiento se caracteriza por ser principalmente reactivo, con demoras en aprobaciones y validaciones manuales, y un aprovechamiento parcial del MRP. Un sistema predictivo puede optimizar los tiempos de reabastecimiento siempre que sus pronósticos se integren al flujo de planificación y se refuercen las prácticas de registro y seguimiento operativo.
- En cuanto a los aspectos económicos y logísticos, se concluye que los costos derivados de quiebres de stock, excesos de inventario, obsolescencia y capital inmovilizado representan un impacto relevante para la empresa. La incorporación de modelos predictivos constituye una alternativa viable para mejorar la disponibilidad de productos, reducir costos logísticos y alinear la gestión de inventarios con los objetivos de transformación digital y competitividad.

6.2. Recomendaciones

6.2.1. Recomendaciones generales

Se recomienda que Home Market Foods avance hacia la implementación gradual de un sistema predictivo de inventarios mediante proyectos piloto, consolidando paralelamente un marco de gobierno de datos y de cultura analítica que garantice la confiabilidad de la información y la apropiación de la herramienta por parte de los usuarios estratégicos.

Asimismo, se sugiere promover nuevas investigaciones aplicadas que profundicen en el impacto de los sistemas predictivos en la cadena de suministro, incorporando enfoques mixtos y comparaciones entre distintos contextos industriales para ampliar el marco teórico disponible.

6.2.2. Recomendaciones específicas

- En relación con los factores técnicos y organizacionales, se recomienda conformar un equipo multidisciplinario que lidere la iniciativa predictiva, establecer políticas claras de calidad de datos e implementar programas de capacitación específicos en analítica y Machine Learning, con el fin de fortalecer la confianza en los modelos y facilitar la adopción tecnológica.
- Respecto a las condiciones operativas y tecnológicas, se recomienda rediseñar el flujo de reabastecimiento para integrar explícitamente los pronósticos del sistema predictivo, simplificar los circuitos de aprobación, revisar los parámetros del MRP y definir indicadores de desempeño que permitan monitorear la mejora en tiempos y cumplimiento de abastecimiento.
- En cuanto a los aspectos económicos y logísticos, se recomienda desarrollar estudios posteriores de carácter cuantitativo que midan el impacto financiero real de la implementación del sistema, así como explorar su extensión a otras plantas o líneas de negocio. Para futuros investigadores, se sugiere profundizar en el estudio de la relación entre cultura de datos, gestión del cambio y éxito de proyectos de Machine Learning en entornos industriales con productos perecibles.

VII. Referencias bibliográficas

- Alarcón, C., & Arteaga, J. (2024). *Propuesta de mejora en la gestión de inventario usando herramientas de Lean Warehousing y Machine Learning de una empresa mayorista de equipos de automatización e instrumentación*. [Repositorio UPC](#).
- Barletti Renteros, K., Estrada Córdova, D., & Verona Aguirre, G. (2023). *Gestión de inventarios y productividad del área de almacén de la empresa L.O. Group*. [Repositorio ISIL](#).
- Barroso, J. (2018). *Modelo predictivo basado en Machine Learning de órdenes de trabajo riesgosas para mantenimiento de equipos mineros*. [Repositorio Universidad de Chile](#).
- Cámara de Comercio de Lima. (2021). *Solo un tercio de empresas en Perú tiene nivel de gestión avanzado en cadena de suministros*. La Cámara de Comercio de Lima. Recuperado de lacamara.pe
- DeLuke, L. (2018). *Predictive Modeling and Optimization of Autoinjector Manufacturing*. [Repositorio MIT](#).
- EY Perú. (2021). *Madurez en la gestión de cadena de suministros: Supply Chain Overview 2021*. Recuperado de [EY](#)
- Figuroa, M., & Reyes, S. (2022). *Gestión de Inventarios a través del Business Intelligence en una empresa del sector Retail: Caso Mumuso*. [Repositorio PUCP](#).

Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2.^a ed.).

O'Reilly Media.

Hernández Sampieri, R., & Mendoza Torres, C. P. (2023). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta* (2^a ed.). McGraw-Hill Education.

Hidalgo Nieto, G. (2024). *La gestión de inventarios y su impacto en la rentabilidad de la empresa Inversiones ITEKNO S.A.* [Repositorio Universidad de Lima](#).

Laudon, K. C., & Laudon, J. P. (2020). *Management information systems: Managing the digital firm* (16th ed.). Pearson.

Mejía, E. (2005). *Metodología de la investigación científica*. Editorial San Marcos.

Microsoft. (2023). *Dynamics 365 documentation*. [Microsoft Learn](#).

Monk, E., & Wagner, B. (2013). *Concepts in enterprise resource planning* (4th ed.). Cengage Learning.

Ñaupas Paitán, H., Mejía Mejía, E., Novoa Ramírez, E., & Villagómez Paucar, J. (2023). *Metodología de la investigación científica y elaboración de tesis* (7^a ed.). Centro de Producción Editorial e Imprenta de la Universidad Nacional Mayor de San Marcos.

Silver, E. A., Pyke, D. F., & Thomas, D. J. (2017). *Inventory and Production Management in Supply Chains* (4.^a ed.). CRC Press.

Vandeput, N. (2021). *Data Science for Supply Chain Forecasting* (2.^a ed.). Wiley.

Waters, D. (2003). *Inventory Control and Management* (2.^a ed.). John Wiley & Sons.

Weinke, M. (2022). *Machine Learning im Logistikmanagement – Entwicklung eines Gestaltungsansatzes zum Einsatz von ML-Anwendungen in logistischen Entscheidungsprozessen*. [LMU München](#).

Yato, D., & Zamudio, J. (2024). *Modelo de gestión de inventarios para el abastecimiento de repuestos de una flota de operaciones aplicando Machine Learning en una mina subterránea del sur del Perú*. [Repositorio UPC](#).

VIII. Anexos

Anexo 01: Informe Turnitin

JAIME JESUS GUERRA TORRES

PA4 - Jaime Guerra - turnitin.docx

Instituto San Ignacio de Loyola - ISIL

Detalles del documento

Identificador de la entrega

trn:oid:::30163:533629756

Fecha de entrega

27 nov 2025, 7:02 p.m. GMT-5

Fecha de descarga

27 nov 2025, 7:16 p.m. GMT-5

Nombre del archivo

PA4 - Jaime Guerra - turnitin.docx

Tamaño del archivo

678.9 KB

57 páginas

15.049 palabras

88.468 caracteres

15% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 11% Fuentes de Internet
- 1% Publicaciones
- 10% Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Jaime Jesus Guerra Torres
(Autor)

Jose Victor Pelaez Valdiviezo
(Asesor)

Anexo 02: Registro de impactos y resultados

Tipo de documento: Trabajo de investigación

Título del Trabajo de Investigación o Tesis

“Propuesta de implementación de un sistema predictivo basado en machine learning para mejorar la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025”

Integrantes:

1. Guerra Torres, Jaime Jesus

Asesor: Peláez Valdivieso, José Víctor

Impacto de la investigación

El impacto de una investigación alude a las consecuencias, previstas o no, que puede producir, e incluye dimensiones económicas, políticas, culturales, ambientales, tecnológicas, sociales, entre otras.

- **Impacto económico:**
 - Reduce pérdidas por quiebres de stock, recuperando ventas actualmente no realizadas.
 - Optimiza niveles de inventario, disminuyendo capital inmovilizado y costos de almacenamiento.
 - Mejora la rentabilidad global al equilibrar disponibilidad de producto y eficiencia operativa.
- **Impacto tecnológico:**
 - Impulsa el uso de Machine Learning y analítica avanzada sobre el ERP existente.
 - Acelera la transición desde reportes descriptivos hacia herramientas predictivas integradas al negocio.
 - Fortalece capacidades internas en ciencia de datos y gobierno de datos.
- **Impacto organizacional:**
 - Promueve una cultura de decisiones basada en evidencia, no solo en experiencia o intuición.
 - Mejora la coordinación entre logística, planificación, finanzas y TI alrededor de un mismo modelo.
 - Disminuye la dependencia de hojas de cálculo y procesos manuales reactivos.
- **Impacto ambiental:**
 - Reduce mermas y vencimientos de productos perecibles al ajustar mejor la oferta a la demanda.
 - Disminuye desperdicio de alimentos y uso ineficiente de recursos productivos.

- Contribuye indirectamente a una cadena de suministro más sostenible y responsable.
- **Impacto académico:**
 - Aporta un caso aplicado de Machine Learning en gestión de inventarios de alimentos perecibles.
 - Genera insumos para comparaciones con otros sectores y contextos industriales.
 - Identifica relaciones entre cultura de datos, adopción tecnológica y éxito de proyectos predictivos.

En resumen, esta investigación propone transformar la gestión de inventarios de Home Market Foods mediante la implementación de un sistema predictivo basado en Machine Learning integrado al ERP corporativo. La propuesta aborda problemas de quiebres de stock, planificación reactiva y uso ineficiente del inventario, orientando a la empresa hacia decisiones sustentadas en datos. Con ello, se fortalece la eficiencia operativa, la disponibilidad de productos para clientes clave y el alineamiento con la transformación digital de la cadena de suministro.

En síntesis, el proyecto plantea una hoja de ruta para aprovechar los datos históricos de inventarios, ventas y producción a través de modelos predictivos que anticipen la demanda y apoyen el reabastecimiento. La investigación no solo ofrece un diseño técnico y organizacional de la solución, sino que también aporta lineamientos de adopción tecnológica, gestión del cambio y alianzas estratégicas, contribuyendo a una operación más rentable, sostenible y basada en una cultura de datos madura.

Resultados del proceso de investigación

Los resultados de un proyecto de investigación corresponden a los hallazgos o conclusiones obtenidos al finalizar el estudio. Representan la información recopilada durante el proceso investigativo y dan respuesta a las preguntas o hipótesis planteadas al inicio del trabajo. Constituyen un componente esencial para valorar, interpretar y comprender los efectos o la solidez de lo investigado.

Los resultados del proceso de investigación evidencian que la implementación de un sistema predictivo de inventarios basado en Machine Learning en Home Market Foods es percibida como viable y pertinente por los colaboradores. La empresa dispone de infraestructura tecnológica adecuada y conocimiento del negocio, pero presenta brechas en calidad de datos, uso efectivo del ERP, dependencia de hojas de cálculo y cultura de datos incipiente. El proceso de reabastecimiento es principalmente reactivo y genera sobrecarga operativa. Los participantes reconocen que un sistema predictivo podría anticipar la demanda, reducir quiebres y excesos de inventario y mitigar pérdidas económicas relevantes.

Anexo 03: Matriz de consistencia

Problema	Objetivo	Hipótesis	Variables y Dimensiones	Metodología	Metodología
Problema General:	Objetivo General:	Hipótesis General:	Variable 1: implementación sistema predictivo basado en machine learning.	Enfoque: - Cualitativo.	Población:
¿Cuáles son los factores que determinan la viabilidad de implementar un sistema predictivo basado en Machine Learning para optimizar la gestión de inventarios en la empresa Home Market Foods, Estados Unidos, 2025?	Evaluar la viabilidad de implementar un sistema predictivo basado en Machine Learning que contribuya a optimizar la gestión de inventarios en la empresa Home Market Foods, Estados Unidos, 2025.	No requiere	Dimensiones: - Capacidades predictivas. - Adopción tecnológica	Tipo de investigación: - Aplicada.	- Empresa Home Market Foods. - Registros del ERP D365 generados por las áreas de Compras, Almacén y Producción.
Problemas específicos	Objetivos específicos	Hipótesis específicas	Variable 2: Gestión de inventarios	Diseño de la investigación: - No experimental de corte transversal.	Muestra: - Personal estratégico de las áreas de Compras, Almacén y Producción de la empresa.
¿Qué factores técnicos y organizacionales influyen en la viabilidad de implementar un sistema predictivo basado en machine learning para mejorar la disponibilidad de productos en Home Market Foods?	Analizar los factores técnicos y organizacionales que influyen en la viabilidad de implementar un sistema predictivo basado en Machine Learning para mejorar la disponibilidad de productos.	No requiere	Dimensiones - Disponibilidad de productos. - Tiempos de reabastecimiento. - Costos asociados al abastecimiento	Nivel de investigación: - Descriptivo	- Registros del ERP a partir del 2024
¿Qué condiciones operativas y tecnológicas deben considerarse para que un sistema predictivo basado en Machine Learning optimice los tiempos de reabastecimiento en Home Market Foods?	Evaluar las condiciones operativas y tecnológicas que permitirían que un sistema predictivo basado en Machine Learning optimice los tiempos de reabastecimiento.	No requiere			
¿Qué aspecto económicos y logísticos determinan la viabilidad de un sistema predictivo basado en Machine Learning para reducir los costos asociados al abastecimiento en Home Market Foods?	Determinar los aspectos económicos y logísticos que influyen en la viabilidad de implementar un sistema predictivo basado en Machine Learning para reducir los costos asociados al abastecimiento.	No requiere			

Anexo 04: Matriz de operacionalización de variables

Variables	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Ítems	Preguntas	I
VI: Sistema predictivo basado en ML	Según Géron (2019), los sistemas de machine learning permiten analizar datos históricos para predecir eventos futuros y apoyar la toma de decisiones estratégicas.	La implementación de un sistema predictivo basado en machine learning para su medición se divide en las siguientes dimensiones: Capacidad predictiva (ítems 1-2) y Adopción tecnológica (ítems 3-4).	Capacidad predictiva	Nivel de confianza en las predicciones	1	¿Qué importancia tiene para su área poder anticipar la demanda futura de productos? ¿por qué?	
				Conocimiento sobre la utilidad del modelo.	2	¿Considera útil predecir la demanda en base a datos históricos? ¿por qué?	
			Adopción tecnológica	Nivel de preparación del equipo.	3	¿Qué tan preparado cree que esta su equipo o área para adoptar una solución tecnológica como un sistema predictivo? ¿por qué?	
				Grado de compatibilidad con procesos actuales	4	¿Qué obstáculos técnicos o de cultura digital ve en la implementación? ¿por qué?	
VD: Gestión de inventarios	Según Silver et al. (2017), la gestión de inventarios busca mantener la disponibilidad de productos minimizando los costos totales asociados a su mantenimiento.	La gestión de inventarios para su medición se divide en las siguientes dimensiones: Disponibilidad (ítems 5-6), Tiempos de reabastecimiento (ítems 7-8) y Costos operativos (9-10).	Disponibilidad	Frecuencia de faltantes	5	¿Con que frecuencia enfrentan problemas de falta de productos en inventario? ¿por qué?	Guía de entrevista
				Impacto en el cumplimiento de pedidos	6	¿Considera que anticipar la demanda ayudaría a reducir los casos de desabastecimiento? ¿por qué?	
			Tiempos de reabastecimiento	Tiempo promedio desde la alerta hasta la reposición	7	¿Cómo describiría la eficiencia actual del proceso de reabastecimiento? ¿por qué?	
				Flujo logístico actual	8	¿Qué parte del proceso genera más demoras? ¿por qué?	
			Costos operativos	Tipos de costos asociados al inventario	9	¿Qué tipos de costos asociados a la gestión de inventarios son más problemáticos en su experiencia? ¿por qué?	
				Potencial ahorro con predicción	10	¿Qué impacto financiero cree que tendría un sistema que optimice los niveles de inventario? ¿por qué?	

Anexo 05: Instrumentos de recolección de datos



GUÍA DE ENTREVISTA

¡Hola! Antes de empezar, agradecería me brindes tu autorización para grabar la entrevista por medio del consentimiento informado.

Mi nombre es Jaime Jesús Guerra Torres, alumno de la Escuela Superior Instituto San Ignacio de Loyola. Estoy realizando una investigación de Pregrado titulada: “**Propuesta de implementación de un sistema predictivo basado en machine learning para mejorar la toma de decisiones en gestión de inventarios de la empresa Home Market Foods de los Estados Unidos, 2025**”. El propósito de esta entrevista es conocer tu opinión sobre el Sistema predictivo basado en machine learning y la Gestión de inventarios. Sus respuestas serán utilizadas únicamente para la investigación y con total confidencialidad.

DATOS SOCIODEMOGRAFICOS

Iniciales del nombre y apellidos:	Fecha:
Genero:	Distrito:
Edad:	Cargo:
Hora de inicio:	Hora de fin:

BLOQUE 1: Sistema predictivo basado en machine learning.

1. ¿Qué importancia tiene para su área poder anticipar la demanda futura de productos? ¿por qué?
2. ¿Considera útil predecir la demanda en base a datos históricos? ¿por qué?
3. ¿Qué tan preparado cree que esta su equipo o área para adoptar una solución tecnológica como un sistema predictivo? ¿por qué?

4. ¿Qué obstáculos técnicos o de cultura digital ve en la implementación? ¿por qué?

BLOQUE 2: Gestión de inventarios.

5. ¿Con que frecuencia enfrentan problemas de falta de productos en inventario? ¿por qué?

6. ¿Considera que anticipar la demanda ayudaría a reducir los casos de desabastecimiento?
¿por qué?

7. ¿Cómo describiría la eficiencia actual del proceso de reabastecimiento? ¿por qué?

8. ¿Qué parte del proceso genera más demoras? ¿por qué?

9. ¿Qué tipos de costos asociados a la gestión de inventarios son más problemáticos en su experiencia? ¿por qué?

10. ¿Qué impacto financiero cree que tendría un sistema que optimice los niveles de inventario? ¿por qué?

Estamos terminando la entrevista, por lo que quisiera saber si tienes algún comentario final que te gustaría realizar.

Muchísimas gracias por tu tiempo, ¡Buen día!