



**FACULTAD DE POSTGRADO
TRABAJO FINAL DE GRADUACIÓN**

**OPTIMIZACIÓN DEL INVENTARIO EN PUNTO DE
VENTA DE LICORES MEDIANTE MODELOS PREDICTIVOS
DE DEMANDA, PERIODO FEBRERO 2024 - OCTUBRE 2025**

**SUSTENTADO POR:
ANGELA MARÍA CASTILLO CUBAS
JOSÉ ALEJANDRO MARTÍNEZ MORENO**

**PREVIA INVESTIDURA AL TÍTULO DE
MÁSTER EN
ANALÍTICA DE NEGOCIOS**

**TEGUCIGALPA, FRANCISCO MORAZAN, HONDURAS, C.A.
FEBRERO, 2026**

**UNIVERSIDAD TECNOLÓGICA
CENTROAMERICANA
UNITEC**

FACULTAD DE POSTGRADO

**AUTORIDADES
UNIVERSITARIAS**

**RECTORA
ROSALPINA RODRÍGUEZ**

**VICERRECTOR ACADÉMICO NACIONAL
JAVIER ABRAHAM SALGADO LEZAMA**

**SECRETARIO GENERAL
ROGER MARTÍNEZ MIRALDA**

**DECANA FACULTAD DE POSTGRADO
ANA DEL CARMEN RETTALLY VARGAS**

**OPTIMIZACIÓN DEL INVENTARIO EN PUNTO DE
VENTA DE LICORES MEDIANTE MODELOS PREDICTIVOS
DE DEMANDA, PERIODO FEBRERO 2024 - OCTUBRE 2025**

**TRABAJO PRESENTADO EN CUMPLIMIENTO DE
LOS REQUISITOS EXIGIDOS PARA OPTAR AL
TÍTULO DE
MÁSTER EN
ANALÍTICA DE NEGOCIOS**

ASESOR

JESÚS RICARDO RODRÍGUEZ RIVERA

**MIEMBROS DE LA TERNA:
ALEJANDRO JOSÉ COLINDRES GALINDO.
KEVIN EDUARDO FUNEZ FUNEZ.
JOSUÉ DAVID MEJÍA RIVERA.**

DERECHOS DE AUTOR

© Copyright 2026

Ángela María Castillo Cubas

José Alejandro Martínez Moreno

Todos los derechos son reservados.



FACULTAD DE POSTGRADO

**OPTIMIZACIÓN DEL INVENTARIO EN PUNTO DE VENTA
DE LICORES MEDIANTE MODELOS PREDICTIVOS DE
DEMANDA, PERIODO FEBRERO 2024 - OCTUBRE 2025**

**ÁNGELA MARÍA
CASTILLO CUBAS**

**JOSÉ ALEJANDRO
MARTÍNEZ MORENO**

Resumen

La presente investigación analiza la aplicación de técnicas de analítica predictiva para optimizar la gestión de inventarios en Licorería Josway, una microempresa dedicada a la comercialización de bebidas alcohólicas en Honduras. El estudio surge ante las limitaciones de los métodos empíricos tradicionales de control de inventarios, los cuales generan quiebres de stock y sobreinventarios que afectan el nivel de servicio y la eficiencia del capital de trabajo.

Se adoptó un enfoque cuantitativo, aplicado y explicativo, utilizando datos históricos de ventas e inventarios correspondientes al período comprendido entre febrero de 2024 y octubre de 2025. A partir de esta información, se desarrollaron y validaron modelos predictivos basados en técnicas de aprendizaje automático, incorporando variables dinámicas como estacionalidad, promociones y eventos locales. La validación se realizó mediante procesos de backtesting y simulación, evaluando el desempeño del modelo a través de métricas de precisión y de indicadores operativos de inventario.

Los resultados evidencian una reducción significativa del error de pronóstico, una disminución de los quiebres de stock y una mejora en la rotación de inventarios, demostrando que la analítica predictiva es viable y efectiva incluso en contextos de micro y pequeñas empresas. El estudio aporta evidencia empírica sobre los beneficios operativos y financieros de la toma de decisiones basada en datos en el sector retail hondureño.

Palabras clave: analítica predictiva, gestión de inventarios, aprendizaje automático, pronóstico de demanda, quiebre de stock, microempresa.



GRADUATE SCHOOL

**OPTIMIZATION OF INVENTORY AT LIQUOR RETAIL
OUTLETS USING PREDICTIVE DEMAND MODELS,
FEBRUARY 2024 - OCTOBER 2025**

**ÁNGELA MARÍA
CASTILLO CUBAS.**

**JOSÉ ALEJANDRO
MARTÍNEZ MORENO.**

Abstract

This research analyzes the application of predictive analytics techniques to optimize inventory management in Licorería Josway, a small retail business dedicated to the commercialization of alcoholic beverages in Honduras. The study addresses the limitations of traditional empirical inventory control methods, which often generate stockouts and overstock situations, affecting service levels and working capital efficiency.

A quantitative, applied and explanatory research approach was adopted, using historical

sales and inventory data from February 2024 to October 2025. Predictive models based on machine learning techniques were developed and validated through backtesting and simulation, incorporating dynamic variables such as seasonality, promotions and local events.

The performance of the proposed model was evaluated using forecast accuracy metrics and operational indicators related to inventory efficiency.

The results demonstrate a significant reduction in forecast error, a decrease in stockouts and an improvement in inventory turnover, confirming the feasibility and effectiveness of predictive analytics in a microenterprise context. This research provides empirical evidence that data-driven inventory management can generate tangible operational and financial benefits, even in organizations with limited technological resources.

Keywords: predictive analytics, inventory management, machine learning, demand forecasting, stockout, micro-enterprise.

DEDICATORIA

Dedicamos este trabajo, en primer lugar, a Dios, por brindarnos la fortaleza, la constancia y la sabiduría necesarias para culminar este proceso académico, aun frente a los retos personales, laborales y académicos que implicó su desarrollo.

A nuestras familias, por su apoyo incondicional, paciencia y motivación permanente, quienes fueron un pilar fundamental durante cada etapa de este camino, impulsándonos a perseverar y a dar lo mejor de nosotros.

A nuestros docentes y asesores, por su orientación académica, exigencia metodológica y acompañamiento constante, que contribuyeron de manera decisiva a fortalecer nuestro pensamiento crítico y la calidad de esta investigación.

Finalmente, dedicamos este trabajo a las micro y pequeñas empresas que buscan mejorar su gestión mediante el uso responsable de los datos y la tecnología, con la convicción de que la analítica de negocios puede convertirse en una herramienta real de transformación, eficiencia y crecimiento sostenible.

AGRADECIMIENTO

Expresamos nuestro sincero agradecimiento a los docentes y asesores de la Maestría en Analítica de Negocios, por su acompañamiento académico, orientación metodológica y valiosas observaciones que contribuyeron al fortalecimiento teórico y práctico de esta investigación.

De manera especial, agradecemos a la empresa Licorería Josway por facilitar el acceso a la información necesaria para el desarrollo del estudio, permitiendo aplicar los conceptos de analítica predictiva en un contexto real y aportar soluciones orientadas a la mejora de su gestión operativa.

Así mismo, agradecemos a la universidad por proveer las herramientas académicas y tecnológicas que hicieron posible la realización de este trabajo, así como a todas las personas que, directa o indirectamente, brindaron apoyo durante el proceso de investigación.

TABLA DE CONTENIDO

DEDICATORIA	xi
AGRADECIMIENTO	xii
TABLA DE CONTENIDO.....	xiii
ÍNDICE DE TABLAS	xviii
ÍNDICE DE ILUSTRACIONES	xx
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN	1
1.1 INTRODUCCIÓN	1
1.2 ANTECEDENTES DEL PROBLEMA.....	2
1.3 PLANTEAMIENTO DEL PROBLEMA	4
1.4 PREGUNTAS DE INVESTIGACIÓN.....	5
1.5 OBJETIVOS DEL PROYECTO	6
1.6 JUSTIFICACIÓN	7
1.6.1 ANÁLISIS CAUSA RAÍZ DEL PROBLEMA DE ABASTECIMIENTO.....	9
CAPÍTULO II. MARCO TEÓRICO	12
2.1 ANÁLISIS DEL MACROENTORNO.....	15
2.2 ANÁLISIS DEL MICROENTORNO (MODELO DE LAS CINCO FUERZAS DE PORTER) 15	
2.3 CONCEPTUALIZACIÓN.....	21
2.4 TEORÍAS DE SUSTENTO.....	23
2.5 ANÁLISIS DE LAS METODOLOGÍAS.....	25
2.6 ANTECEDENTES DE METODOLOGÍAS	27
2.7 METODOLOGÍAS, ENFOQUES Y DISEÑOS	29
2.7.1 METODOLOGÍA DEL ESTUDIO.....	29
2.7.2 ENFOQUES Y TIPOS DE INVESTIGACIÓN.....	30
2.7.3 DISEÑO DE INVESTIGACIÓN.....	30
2.8 ANÁLISIS CRÍTICO DE METODOLOGÍAS	31
2.9 HERRAMIENTAS POR UTILIZAR.....	34
2.10 MARCO LEGAL (PROTOSCOLOS, ACUERDOS, LEYES, ETC.....	35
2.10.1 MARCO LEGAL NACIONAL	35

2.10.2	MARCO LEGAL INTERNACIONAL.....	37
CAPÍTULO III. METODOLOGÍA		38
3.1	CONGRUENCIA METODOLÓGICA	38
3.1.1	MATRIZ METODOLÓGICA	38
3.1.2	ESQUEMA DE VARIABLES DE ESTUDIO.....	45
3.1.3	OPERACIONALIZACIÓN DE LAS VARIABLES.....	47
3.1.4	HIPÓTESIS.....	49
3.2	ENFOQUE Y MÉTODOS.....	50
3.3	DISEÑO DE LA INVESTIGACIÓN	50
3.3.1	POBLACIÓN.....	51
3.3.2	CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN	51
3.3.2	MUESTRA	52
3.3.3	TÉCNICAS DE MUESTREO	52
3.4	TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS.....	54
3.4.1.	TÉCNICAS DE ANÁLISIS.....	55
3.4.2.	PROCEDIMIENTOS	56
3.5	FUENTES DE INFORMACIÓN	56
3.5.1	FUENTES DE DATOS PRIMARIAS	57
3.5.2	FUENTES SECUNDARIAS.....	57
3.6	PLAN DE ANÁLISIS.....	57
CAPÍTULO IV. RESULTADOS Y ANÁLISIS		60
4.1	ANÁLISIS EXPLORATORIO DE DATOS (EDA).....	61
4.1.1	DESCRIPCIÓN GENERAL DEL CONJUNTO DE DATOS.....	61
4.1.2	LIMPIEZA Y PREPARACIÓN DE LOS DATOS.....	63
4.1.3	ANÁLISIS DE DESCOMPOSICIÓN DE SERIES DE TIEMPO.....	69
4.1.4.	VISUALIZACIÓN DE DATOS	71
4.1.5.	CONCLUSIONES DEL EDA	85
4.1.4.1	CARACTERIZACIÓN GENERAL DEL CONJUNTO DE DATOS....	85
4.1.4.2	COMPORTAMIENTO DE LAS VARIABLES CUANTITATIVAS ...	85
4.1.4.3	DISTRIBUCIÓN POR ESTRATOS Y CONCENTRACIÓN DEL	
NEGOCIO.....		86

4.1.4.4	RELACIONES ENTRE VARIABLES Y PATRONES IDENTIFICADOS	86
4.1.4.5	VALORES ATÍPICOS Y SU INTERPRETACIÓN	87
4.1.4.6	VALIDACIÓN DEL DISEÑO MUESTRAL	87
4.1.4.7	LIMITACIONES Y CONSIDERACIONES METODOLÓGICAS	87
4.1.4.8	CONCLUSIÓN GENERAL	88
4.2	INFORME DEL PROCESO DE RECOLECCIÓN DE DATOS.....	88
4.2.1	DESCRIPCIÓN DEL PROCESO.....	88
4.2.1.1	ETAPAS DEL PROCESO DE RECOLECCIÓN	89
4.2.1.2	RECURSOS UTILIZADOS	90
4.2.1.3	TEMPORALIDAD DEL PROCESO	91
4.2.2	PARTICIPANTES O FUENTES DE INFORMACIÓN	91
4.2.2.1	CARACTERÍSTICAS DE LA POBLACIÓN ESTUDIADA.....	91
4.2.2.2	CARACTERÍSTICAS DE LA MUESTRA SELECCIONADA.....	92
4.2.3	INSTRUMENTOS UTILIZADOS.....	92
4.2.3.1	NATURALEZA DE LOS INSTRUMENTOS.....	92
4.2.3.2	SISTEMA DE GESTIÓN COMO INSTRUMENTO DE CAPTURA ..	92
4.2.3.3	HERRAMIENTAS DE PROCESAMIENTO Y ANÁLISIS	93
4.2.3.4	CONSULTAS INFORMALES NO ESTRUCTURADAS	94
4.2.4	DIFICULTADES ENCONTRADAS	95
4.2.4.1	INCONSISTENCIAS EN LA CATEGORIZACIÓN DE PRODUCTOS	95
4.2.4.2	PROBLEMAS DE FORMATO EN ARCHIVOS EXCEL	95
4.2.5	CONSIDERACIONES ÉTICAS	96
4.2.5.1	MARCO ÉTICO DEL ESTUDIO	96
4.2.5.2	AUTORIZACIÓN FORMAL PARA USO DE DATOS	96
4.2.5.3	CONFIDENCIALIDAD Y PROTECCIÓN DE DATOS	97
4.2.5.4	INTEGRIDAD EN EL MANEJO DE DATOS.....	98
4.3	RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS.....	100
4.3.1	RESULTADOS CUANTITATIVOS	101
4.3.1.1	PRESENTACIÓN DE DATOS.....	101

4.3.1.2	DESCRIPCIÓN DE LOS HALLAZGOS	106
4.3.1.3	RELACIÓN CON LOS OBJETIVOS DE INVESTIGACIÓN.....	109
4.3.1.4	ANÁLISIS ESTADÍSTICO.....	110
4.3.2	ANÁLISIS CUALITATIVO	126
4.3.2.1	CATEGORÍAS O TEMAS EMERGENTES	127
4.3.2.2	CITAS O EJEMPLOS	128
4.3.2.3	INTERPRETACIÓN	128
4.3.2.4	TRIANGULACIÓN	129
4.4	ANÁLISIS INFERENCIAL Y MODELOS APLICADOS	131
4.4.1	ANÁLISIS INFERENCIAL	131
4.4.2	MODELOS APLICADOS.....	133
4.4.3	DISCUSIÓN DE HALLAZGOS.....	133
4.4.4	LIMITACIONES	134
4.5	SÍNTESIS DE HALLAZGOS	134
4.5.1	PRINCIPALES HALLAZGOS	134
4.5.2	IMPLICACIONES.....	135
4.5.3	TRANSICIÓN AL CAPÍTULO V	136
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....		137
5.1	CONCLUSIONES	137
5.2	RECOMENDACIONES.....	138
CAPÍTULO VI. APLICABILIDAD.....		139
6.1	NOMBRE DE LA PROPUESTA.....	139
6.2	JUSTIFICACIÓN DE LA PROPUESTA.....	139
6.2.1.	FUNDAMENTACIÓN DESDE LOS HALLAZGOS DE LA INVESTIGACIÓN.....	139
6.2.2	SUSTENTO TEÓRICO DE LA PROPUESTA	139
6.2.3	PERTINENCIA Y VIABILIDAD	140
6.2.4	IMPACTO ESPERADO.....	140
6.3	ALCANCE DE LA PROPUESTA	141
6.4	DESCRIPCIÓN Y DESARROLLO.....	141
6.4.1	DESCRIPCIÓN	141

6.4.2	DESARROLLO DE DASHBOARD PREDICTIVO INTERACTIVO	143
6.5	MEDIDAS DE CONTROL	147
6.6	CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO	153
6.7	PRESUPUESTO E IMPACTO.....	157
6.7.1	PRESUPUESTO DESGLOSADO	157
6.7.2	BENEFICIOS ECONÓMICOS ESTIMADOS	159
6.7.3	CÁLCULO DEL ROI.....	159
6.7.4	IMPACTO CUANTITATIVO.....	161
6.7.5	IMPACTO CUALITATIVO	161
6.7.6	CONCLUSIÓN DEL PRESUPUESTO Y ROI.....	162
6.8	CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA	163
	REFERENCIAS BIBLIOGRÁFICAS.....	167
	ANEXOS	171
	Anexo 1: CARTA DE AUTORIZACIÓN PARA EL USO DE DATOS.....	171
	Anexo 2: DIAGRAMA DE GANTT – ANÁLISIS DE TIEMPOS DE LA INVESTIGACIÓN.....	172

ÍNDICE DE TABLAS

Tabla 1: Análisis Cinco Fuerzas de Porter en el sector licorero minorista.....	16
Tabla 2 Análisis Comparativo PESTEL en la Industria Licorera Minorista.....	18
Tabla 3 :Análisis de Riesgos Metodológicos y Mitigaciones Josway	33
Tabla 4 Librerías y Frameworks	34
Tabla 5: Matriz de congruencia metodológica.....	39
Tabla 6: Matriz de Operacionalización.....	47
Tabla 7: Detalles de la población de estudio	51
Tabla 8: Criterios de inclusión y exclusión.....	52
Tabla 9: Clasificación ABC en inventarios	53
Tabla 10: Clasificación de productos pareto licorería JosWay.....	53
Tabla 11: Clasificación de estratos	54
Tabla 12: Análisis de Tiempos	57
Tabla 13 Métricas Generales	61
Tabla 14 Estadísticas Generales.....	62
Tabla 15 Interpretación Valores Atípicos	63
Tabla 16: Estadísticas Generales sin outliers.....	64
Tabla 17 Normalización y Estandarización de los Datos	66
Tabla 18:Percentiles de las variables cuantitativas.....	67
Tabla 19: Distribución de transacciones por estrato	74
Tabla 20: Resumen de outliers.....	84
Tabla 21 Principios Éticos Aplicados en el Proceso de Investigación	98
Tabla 22 Resultados de la Clasificación ABC del Portafolio de Productos	101
Tabla 23 Distribución de Clasificación ABC por Estrato de Producto	102
Tabla 24 Estadísticas Descriptivas de Productos Clase A	103
Tabla 25: Rotación por categoría.....	105
Tabla 26: Estrategias para el entrenamiento de modelos.....	111
Tabla 27: Definición detallada de las variables predictoras del modelo	115
Tabla 29:Resultados de pruebas Wilcoxon.....	125
Tabla 30 Categorías codificadas del análisis documental.....	127

Tabla 31 Triangulación de hallazgos cualitativos y cuantitativos	129
Tabla 32 Pruebas de Normalidad - Shapiro-Wilk.....	131
Tabla 33: Mejoras en los hallazgos de la investigación.....	139
Tabla 34: Objetivos por horizonte de tiempo	141
Tabla 35: Representación visual del diseño de la hoja 1	143
Tabla 36: Representación visual del diseño de la tabla interactiva (Hoja 2).....	144
Tabla 37: Representación visual del diseño de análisis de precisión del modelo.....	145
Tabla 38: Representación visual diseño del tablero de KPIs.....	145
Tabla 39 Beneficios Económicos Estimados por Escenario.....	159
Tabla 40 ROI Proyectado con Tres Escenarios (12 Meses)	159
Tabla 41 Matriz de Concordancia.....	163

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Diagrama Causa Raíz	10
Ilustración 2: Esquema de las variables de estudio.....	45
Ilustración 3: División de enfoque y métodos	50
Ilustración 4 Diagrama de subdivisión de técnicas.....	55
Ilustración 5: Representación de tendencias en la información de JosWay	69
Ilustración 6: Representación gráfica de estacionalidad.....	70
Ilustración 7: Histograma de variables cuantitativas	71
Ilustración 8: Diagramas de caja para identificación de valores atípicos	72
Ilustración 9: Estimación de densidad Kernel de las variables cuantitativas.....	73
Ilustración 10: Distribución de frecuencias por estrato	75
Ilustración 11: Proporción relativa de transacciones por estrato	76
Ilustración 12: Distribución de transacciones por clasificación ABC	77
Ilustración 13: Top 20 productos más vendidos	78
Ilustración 14: Evolución temporal de transacciones mensuales.....	79
Ilustración 15: Distribución de transacciones por día de la semana	80
Ilustración 16: Comparación de utilidad por estrato.....	81
Ilustración 17: Matriz de correlación de Pearson entre variables cuantitativas.....	82
Ilustración 18: Matriz de diagrama de dispersión.....	83
Ilustración 19: Etapas del proceso de recolección de datos	89
Ilustración 20: Evidencia pruebas de hipótesis	125
Ilustración 21: Diagnóstico de normalidad mediante gráficos Q-Q	132
Ilustración 22: Arquitectura de la Solución	142

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1 INTRODUCCIÓN

En el sector minorista de bebidas alcohólicas, la gestión eficiente del inventario constituye un elemento esencial para garantizar la disponibilidad de productos, satisfacer la demanda del consumidor y mantener la rentabilidad del negocio. Las micro, pequeñas y medianas empresas (Mipymes) representan cerca del 99% del total de las empresas en Honduras y generan aproximadamente el 70% del empleo formal, siendo un pilar fundamental de la economía nacional (Secretaría de Desarrollo Económico de Honduras, 2023). Dentro de este conjunto, los comercios dedicados a la venta de bebidas alcohólicas y productos afines muestran una participación creciente, impulsada por el aumento del consumo interno y la diversificación del mercado minorista.

No obstante, la mayoría de las Mipymes hondureñas carecen de herramientas tecnológicas avanzadas para la gestión de inventarios. Según la (Comisión Económica para América Latina y el Caribe, 2023), solo el 18% de las pequeñas empresas de la región emplean sistemas digitales de control de inventarios o análisis de datos, lo que las expone a altos niveles de ineficiencia operativa. En el caso de las licorerías minoristas, esta situación se traduce en rupturas de stock de hasta un 25% durante temporadas altas y en sobre inventarios que superan el 30% en períodos de baja demanda, generando pérdidas por obsolescencia y capital inmovilizado (Banco Interamericano de Desarrollo, 2022).

Tradicionalmente, negocios como Licorería Josway, ubicada en Ciudad La Paz, La Paz, han gestionado su abastecimiento de forma empírica, basándose en la experiencia del propietario o en registros históricos de ventas. Aunque este enfoque ha permitido sostener operaciones básicas, resulta insuficiente ante las variaciones de la demanda influenciadas por factores estacionales, festividades locales y promociones de marcas específicas. La falta de integración de modelos analíticos predictivos limita la capacidad del negocio para anticiparse a la demanda, generando costos innecesarios y pérdida de oportunidades de venta.

El presente estudio propone el desarrollo de un modelo predictivo de demanda e inventario que incorpore técnicas de aprendizaje automático e inteligencia artificial, con el propósito de mejorar la precisión de las estimaciones de consumo y optimizar la reposición de productos en

Licorería Josway. A través del análisis de datos históricos de ventas y variables externas como el calendario de festividades, la temperatura y el comportamiento del consumidor local se busca reducir costos operativos, minimizar desperdicios y maximizar la disponibilidad de productos estratégicos.

De esta manera, la investigación contribuye al proceso de transformación digital del sector Mipyme hondureño, promoviendo una cultura empresarial orientada a la toma de decisiones basada en datos. Este enfoque no solo fortalece la sostenibilidad y rentabilidad de negocios como Licorería Josway, sino que también mejora su competitividad frente a cadenas comerciales de mayor escala que ya implementan herramientas de analítica avanzada.

Finalmente, para abordar este desafío, el presente documento se estructura en tres capítulos:

- El Capítulo I presenta el contexto general del estudio, los antecedentes, la formulación del problema, los objetivos y la justificación de la investigación.
- El Capítulo II desarrolla el marco teórico, abarcando la fundamentación conceptual, las teorías de sustento y el análisis de metodologías relacionadas con la predicción de demanda y gestión de inventarios.
- El Capítulo III expone el diseño metodológico aplicado para la construcción y validación del modelo predictivo propuesto, junto con las técnicas de análisis utilizadas y la interpretación de los resultados.

1.2 ANTECEDENTES DEL PROBLEMA

El abastecimiento eficiente de inventarios constituye un desafío central en la gestión de la cadena de suministro, especialmente en sectores de alta rotación como el comercio minorista de bebidas alcohólicas. En este contexto, negocios como Licorería Josway enfrentan la necesidad de mantener una disponibilidad óptima de productos que garantice la satisfacción del cliente y, simultáneamente, reduzca las pérdidas por sobre inventario o desabastecimiento. Sin embargo, la ausencia de herramientas analíticas y metodologías predictivas limita significativamente la capacidad de respuesta de las Mipymes del sector ante las fluctuaciones del mercado.

Tradicionalmente, las licorerías han gestionado su inventario mediante métodos empíricos

basados en el registro histórico de ventas y la observación directa del stock disponible. Si bien estos enfoques constituyen un punto de partida funcional, presentan limitaciones estructurales al ignorar variables dinámicas como eventos sociales locales, promociones estacionales, festividades nacionales o cambios en las preferencias de consumo. La falta de mecanismos de anticipación genera desequilibrios logísticos caracterizados por sobre inventarios que inmovilizan capital y reducen la liquidez y rupturas de stock que ocasionan pérdidas de ventas y disminución en la fidelización del cliente.

La literatura reciente confirma la ineficiencia de los modelos reactivos en contextos comerciales dinámicos. (Syntetos et al., 2022) sostienen que los métodos basados exclusivamente en datos históricos generan respuestas tardías ante variaciones de la demanda y elevan los costos de mantenimiento de inventarios. De forma complementaria (Boone et al., 2023) argumentan que la carencia de técnicas predictivas impide capturar la complejidad del comportamiento del consumidor moderno, lo que deriva en acumulación de productos de baja rotación y escasez de los artículos más demandados. No obstante, la mayoría de estos estudios se han concentrado en grandes corporaciones o cadenas internacionales, dejando un vacío empírico en la aplicación de tales modelos al contexto de las Mipymes latinoamericanas.

En Honduras, esta brecha se acentúa por la limitada digitalización empresarial. De acuerdo con la (Secretaría de Desarrollo Económico de Honduras, 2023), más del 75% de los comercios minoristas administran sus inventarios sin sistemas tecnológicos de apoyo, lo que restringe su capacidad de adaptación y competitividad frente a empresas que ya integran inteligencia artificial en sus procesos operativos. Esta carencia es especialmente relevante en el sector licorero, donde la demanda presenta alta estacionalidad y sensibilidad ante factores externos.

En este marco, el caso de Licorería Josway ejemplifica los retos estructurales de las Mipymes hondureñas. El negocio utiliza un sistema manual sustentado en variables básicas histórico de ventas, nivel actual de inventario, frecuencia de reposición y disponibilidad del catálogo que, si bien ha permitido mantener la operación diaria, no ofrece capacidad predictiva. En consecuencia, el proceso de reposición es reactivo, dependiendo de la experiencia del propietario más que del análisis objetivo de datos.

La síntesis crítica de los antecedentes evidencia, por tanto, una brecha de conocimiento en la aplicación de modelos predictivos de demanda e inventario en pequeñas empresas del sector

licorero hondureño. Mientras la literatura internacional resalta el potencial del aprendizaje automático y la analítica avanzada para optimizar la gestión del stock, la falta de estudios y validaciones locales justifica la pertinencia de esta investigación. El presente trabajo se propone llenar dicho vacío mediante el diseño e implementación de un modelo predictivo adaptado a la realidad operativa de Licorería Josway, contribuyendo al fortalecimiento tecnológico y a la sostenibilidad competitiva del sector.

1.3 PLANTEAMIENTO DEL PROBLEMA

El sistema actual de gestión de inventarios en Licorería Josway se basa en métodos tradicionales sustentados en el análisis histórico de ventas y el control manual de los niveles de stock. Aunque este enfoque ha permitido mantener la continuidad operativa del negocio, presenta limitaciones estructurales importantes, ya que no considera factores externos como las tendencias de consumo local, los eventos festivos o las variaciones económicas que influyen directamente en la demanda de bebidas alcohólicas. La ausencia de herramientas predictivas integradas provoca desequilibrios en el abastecimiento, evidenciados por episodios de desabastecimiento y sobre inventario, los cuales afectan la rentabilidad, la rotación de productos y la satisfacción del cliente.

En un análisis preliminar realizado sobre los registros de ventas de los últimos seis meses, se identificó que alrededor del 15% de los productos de mayor rotación (aproximadamente 10 SKU) presentaron episodios de quiebre de stock durante eventos de alta demanda, como ferias patronales y festividades nacionales. Este desabastecimiento representa una pérdida estimada de oportunidad de venta del 12% mensual en dichas categorías. Por otro lado, se evidenció la acumulación de inventario en un 25% de las referencias de baja rotación, lo que genera inmovilización de capital, incremento de costos de almacenamiento y riesgo de deterioro de mercancía.

Entre las principales deficiencias del sistema actual se destacan:

- Baja adaptabilidad ante cambios del mercado: la demanda de bebidas alcohólicas varía significativamente durante celebraciones locales (como Navidad, Semana Santa o ferias municipales).
- Ausencia de sensibilidad estacional y promocional: los picos de demanda relacionados con promociones o campañas de marcas no son anticipados

adecuadamente, generando proyecciones erróneas y sobrecostos operativos.

- Gestión uniforme de productos heterogéneos: el modelo actual no distingue entre categorías con comportamientos distintos (por ejemplo, cervezas, ronones populares y licores premium), impidiendo aplicar políticas diferenciadas de reposición y control según su rentabilidad o velocidad de rotación (Boone et al., 2023).
- Dependencia empírica en la toma de decisiones: ante la falta de un sistema analítico, las decisiones de compra y reposición dependen del criterio del propietario o del personal de tienda. Esta subjetividad provoca variabilidad en los resultados e impide establecer estrategias consistentes de planificación.

Estas deficiencias reflejan un modelo de gestión reactivo que responde a los cambios del mercado una vez ocurridos, en lugar de anticiparlos. Según la (Secretaría de Desarrollo Económico de Honduras, 2023) las Mipymes del sector retail en Honduras pierden entre 10% y 25% de sus ventas anuales debido a una gestión ineficiente del inventario.

En consecuencia, Licorería Josway enfrenta la necesidad de migrar hacia un modelo predictivo basado en analítica avanzada y aprendizaje automático, capaz de integrar variables dinámicas como estacionalidad, promociones y eventos locales para anticipar la demanda y optimizar la reposición. Este cambio permitiría reducir las pérdidas operativas, mejorar la eficiencia del capital de trabajo y aumentar la competitividad del negocio en el mercado local.

1.4 PREGUNTAS DE INVESTIGACIÓN

Pregunta General:

En (P) la empresa Licorería Josway, ¿De qué manera la (I) implementación de un modelo predictivo multivariable basado en machine learning que integra características temporales, económicas y de producto, en (C) comparación con el sistema empírico actual de gestión manual, (O) permite reducir el error de predicción de demanda y optimizar los niveles de inventario durante el periodo febrero 2024 a octubre 2025?

Preguntas Específicas:

1. En (P) el portafolio de productos de Licorería Josway, ¿De qué forma la (I) clasificación basada en análisis de estratos por categoría de producto, en (C) comparación con la gestión uniforme actual del inventario, (O) permite identificar los artículos con mayor criticidad de abastecimiento según su rotación y contribución a las ventas?
2. En (P) los productos de alta rotación de Licorería Josway, ¿De qué forma la (I) integración de múltiples características predictoras (patrones de demanda histórica, variables temporales y precios), en (C) comparación con proyecciones basadas únicamente en media móvil simple, (O) incrementa la precisión del pronóstico y reduce los errores de predicción (MAE y MAPE)?
3. En (P) el sistema de gestión de inventarios de Licorería Josway, ¿De qué manera la (I) implementación de un modelo predictivo de demanda con técnicas de machine learning, en (C) comparación con el método empírico actual, (O) contribuye a reducir los niveles de sobre inventario y quiebres de stock, optimizando la planificación de pedidos y la rentabilidad del negocio?

1.5 OBJETIVOS DEL PROYECTO

Objetivo General:

Analizar (S) los patrones históricos de ventas en Licorería Josway mediante técnicas de machine learning y análisis descriptivo, (M) identificando los productos con mayor rotación, rentabilidad y sensibilidad, (A) a partir del procesamiento de datos reales de ventas comprendidos entre febrero de 2024 y octubre de 2025, (R) para determinar los artículos que deben mantener niveles prioritarios de stock en función de la demanda proyectada y el margen de contribución, (T) durante el periodo de investigación comprendido entre febrero 2024 y octubre 2025.

Objetivos Específicos:

- Analizar y clasificar (S) el portafolio de productos de Licorería Josway con base en su volumen de ventas, frecuencia de rotación y estabilidad de la demanda, (M) utilizando indicadores de rotación mensual y métodos de categorización ABC–XYZ para medir el comportamiento de cada producto. (A) Este análisis se desarrollará a partir de los registros históricos de ventas comprendidos entre febrero

de 2024 y octubre de 2025, (R) con el propósito de identificar los artículos que deben mantener distintos niveles de inventario según su criticidad comercial y aporte a la rentabilidad del negocio, (T) dentro del periodo de investigación correspondiente al año 2025.

- Evaluar (S) la contribución de múltiples características predictoras (patrones históricos de demanda, variables temporales y atributos de producto) sobre la precisión del pronóstico de ventas en los productos de alta rotación de Licorería Josway, mediante (M) el análisis de importancia de variables en modelos de machine learning y la comparación de métricas de error (MAE, MAPE) contra métodos tradicionales basados en media móvil, durante el periodo febrero 2024 a octubre 2025. (A) El estudio empleará técnicas de feature importance y validación estadística accesibles para una mipyme minorista, (R) con el fin de determinar qué características tienen mayor impacto en la precisión de los pronósticos de demanda y en la planificación del inventario, (T) contribuyendo a optimizar las decisiones de reabastecimiento en el transcurso del año 2025.
- Diseñar (S) un modelo de optimización de inventarios que, basado en los patrones de demanda identificados y los resultados del análisis predictivo, (M) permita comparar los niveles de stock sugeridos con los históricos de ventas y medir su efecto en la reducción de quiebres de stock y sobre inventarios. (A) El modelo se implementará de forma experimental utilizando un subconjunto de los productos más representativos de Licorería Josway, (R) buscando maximizar la rentabilidad y la eficiencia del uso del capital de trabajo mediante una gestión predictiva más precisa, (T) aplicando la validación de resultados durante los meses finales del segundo semestre de 2025.

1.6 JUSTIFICACIÓN

El presente estudio se justifica académicamente por su contribución al desarrollo de metodologías analíticas aplicadas a la gestión de inventarios en micro y pequeñas empresas (Mipymes) del sector minorista hondureño. Aunque la literatura internacional sobre modelos predictivos de demanda es extensa, más del 80% de las investigaciones empíricas se centran en grandes cadenas de suministro o corporaciones con infraestructura tecnológica avanzada

(Deloitte, 2024). Esta concentración evidencia una brecha académica en la validación de modelos predictivos en contextos de baja digitalización y recursos limitados, como los que caracterizan al sector Mipyme en Honduras.

Según la Secretaría de Desarrollo Económico (Secretaría de Desarrollo Económico de Honduras, 2024), el 72% de las Mipymes hondureñas carece de sistemas automatizados de control de inventarios, lo que ocasiona pérdidas de entre 10% y 25% de sus ventas anuales por sobre stock o desabastecimiento. Este panorama se replica en el sector de bebidas alcohólicas, donde la falta de herramientas analíticas limita la capacidad de anticipación ante picos de demanda estacional y promociones de marca. En este contexto, Licorería Josway constituye un caso representativo, ya que su gestión empírica de inventarios genera desequilibrios entre la disponibilidad de productos y la variabilidad de la demanda local.

Desde el punto de vista teórico, la investigación se sustenta en la integración de la teoría de la gestión de inventarios (Silver et al., 2016), la teoría de la predicción de la demanda (Box & Jenkins, 1976) y los principios del aprendizaje automático aplicados a la analítica empresarial (Zhang & Zhao, 2022). Esta convergencia interdisciplinaria fortalece la comprensión de cómo las variables dinámicas como estacionalidad, promociones y eventos locales inciden sobre los patrones de consumo, permitiendo construir modelos predictivos adaptados a entornos de alta incertidumbre.

Metodológicamente, el estudio incorpora modelos de machine learning (Random Forest, XGBoost y Regresión Lineal) para analizar datos históricos de ventas (febrero 2024 a octubre 2025), combinados con el método ABC para clasificar productos según su rotación y variabilidad. Esta integración permite no solo identificar los artículos críticos para el abastecimiento, sino también validar la efectividad del modelo predictivo mediante métricas cuantificables de error y eficiencia operativa. El resultado esperado no es únicamente una herramienta funcional, sino evidencia empírica sobre el impacto de la analítica predictiva en microempresas del sector retail.

En el ámbito social y económico, la investigación tiene relevancia práctica al demostrar cómo el uso de modelos analíticos accesibles puede reducir pérdidas operativas hasta en un 20% y aumentar la disponibilidad de productos clave en un 15%, de acuerdo con proyecciones basadas en estudios de (Deloitte, 2023) y el (Banco Interamericano de Desarrollo, 2024).

Asimismo, promueve una cultura empresarial orientada a la toma de decisiones basada en datos, contribuyendo al Objetivo de Desarrollo Sostenible (ODS 9) sobre innovación e infraestructura y al ODS 8 sobre trabajo decente y crecimiento económico (Organización de las Naciones Unidas, 2023).

Finalmente, el estudio es relevante porque:

- Aporta evidencia científica sobre la relación entre variables contextuales y optimización de inventarios en mercados emergentes.
- Integra modelos teóricos y metodológicos de la analítica avanzada con la realidad operativa de una Mipyme hondureña.
- Genera conocimiento replicable en otros sectores minoristas de la región.
- Fortalece la competitividad local, posicionando a Licorería Josway como un referente en innovación predictiva aplicada al comercio minorista.

En síntesis, esta investigación trasciende la utilidad operativa de un modelo, consolidándose como una contribución académica significativa al campo de la analítica de negocios en entornos de recursos limitados.

1.6.1 ANÁLISIS CAUSA RAÍZ DEL PROBLEMA DE ABASTECIMIENTO

El análisis de causa raíz (ACR) constituye una herramienta metodológica fundamental para identificar los factores estructurales que generan ineficiencias dentro de la gestión de inventarios. En el caso de Licorería Josway, su aplicación permite comprender cómo las deficiencias operativas, tecnológicas y de planificación afectan directamente la disponibilidad de productos, la rotación del stock y la rentabilidad del negocio.

Para ello, se emplea el Diagrama de Ishikawa (Ishikawa, 1986), también conocido como diagrama causa efecto, el cual clasifica las causas del problema en seis categorías principales: métodos, mano de obra, materiales, maquinaria/tecnología, medición y medio ambiente. Esta metodología ha sido utilizada en estudios recientes de optimización de inventarios minoristas, donde se evidencia que la falta de digitalización y la dependencia del criterio empírico son las principales fuentes de error en la predicción de demanda (Boone et al., 2023).

Ilustración 1: Diagrama Causa Raíz



Fuente: Elaboración propia.

Análisis interpretativo del ACR

El diagrama de Ishikawa evidencia que el problema de abastecimiento en Licorería Josway manifestado en quiebres de stock y sobre inventario es de carácter multicausal, concentrándose principalmente en las dimensiones de métodos, tecnología y medición. Desde la perspectiva de métodos, la gestión empírica y reactiva, basada únicamente en la experiencia del personal y en registros históricos simples, ha generado una baja capacidad de anticipación de la demanda; como resultado, se han identificado periodos con quiebres de stock superiores al 20% en productos de alta rotación durante temporadas festivas, así como acumulación de inventario de baja demanda que representa hasta un 17% de sobre inventario, inmovilizando capital de trabajo. En la dimensión de mano de obra, la dependencia de decisiones individuales y la falta de capacitación en análisis de datos limitan la consistencia de las decisiones de reposición, incrementando la variabilidad operativa.

En cuanto a tecnología, el uso básico de hojas de cálculo y la ausencia de sistemas automatizados impiden el cálculo oportuno de indicadores clave, lo que se traduce en errores de pronóstico superiores al 25% (MAPE) bajo el método tradicional. Asimismo, la dimensión de medición revela la inexistencia de KPIs formales como fill rate o precisión del pronóstico, dificultando el control del desempeño del inventario.

Finalmente, el medio ambiente, caracterizado por estacionalidad, festividades locales y cambios en los patrones de consumo, introduce variaciones de demanda de hasta 30% entre semanas, las cuales no son capturadas por los enfoques tradicionales. En conjunto, este análisis causal sustenta la necesidad de implementar un modelo predictivo basado en aprendizaje automático, capaz de integrar variables dinámicas y reducir de forma significativa tanto los quiebres de stock como el sobre inventario, fortaleciendo la eficiencia operativa y la toma de decisiones basada en datos.

CAPÍTULO II. MARCO TEÓRICO

La gestión eficiente del inventario en el sector minorista de bebidas alcohólicas constituye un componente esencial para la sostenibilidad y rentabilidad de las Mipymes. En Honduras, este segmento económico enfrenta importantes desafíos derivados de la alta rotación de productos, la estacionalidad de la demanda y la limitada incorporación de tecnologías de análisis predictivo. Según la (Rodríguez & Huete, 2024), el 78% de las pequeñas empresas de comercio minorista aún gestionan sus inventarios de forma manual, basándose únicamente en registros históricos y experiencia empírica, lo que reduce su eficiencia operativa y capacidad de respuesta ante cambios en el mercado.

En negocios como Licorería Josway, ubicada en Ciudad La Paz, La Paz, la variabilidad de la demanda se ve influenciada por factores como eventos locales, festividades nacionales, promociones y cambios en las preferencias del consumidor. Esta dinámica exige una planificación de inventarios más flexible y orientada a la predicción, capaz de anticipar comportamientos de consumo y evitar tanto el desabastecimiento como el exceso de productos de baja rotación.

Evolución de los sistemas de predicción de demanda

En la última década, los modelos de gestión de inventarios en el sector retail han evolucionado de métodos puramente estadísticos hacia sistemas de analítica avanzada e inteligencia artificial. Tradicionalmente, las empresas utilizaban herramientas como promedios móviles, suavización exponencial o modelos ARIMA, los cuales, si bien ofrecían un punto de partida útil, resultaban limitados al no integrar variables externas ni cambios abruptos en la demanda (Taylor, 2021).

Estudios recientes en Mipymes latinoamericanas indican que más del 60% de los negocios minoristas aún dependen de métodos históricos reactivos, generando ineficiencias tangibles. Actualmente, la organización presenta una precisión en los pronósticos que oscila entre el 65% y el 75%, lo que impacta directamente en la planificación de la demanda. Asimismo, los costos de inventario representan entre el 20% y el 30% del valor total de la mercancía, generando una carga financiera significativa. A esto se suman las pérdidas por desabastecimiento, estimadas entre el 4% y el 9% de las ventas potenciales, así como excesos de inventario que afectan aproximadamente entre el 15% y el 25% del catálogo activo, evidenciando ineficiencias en la gestión del inventario

(Boone et al., 2023).

Por otro lado, (Martínez-López & Gómez, 2024) destacan que la incorporación de variables dinámicas como estacionalidad, promociones o eventos locales puede aumentar la precisión de los pronósticos entre un 15% y 30%, mejorando sustancialmente la planificación del abastecimiento y reduciendo costos logísticos.

Tendencias actuales en modelos predictivos para la gestión de inventarios

Los avances en ciencia de datos y aprendizaje automático han impulsado una nueva generación de herramientas predictivas aplicadas al comercio minorista. Según (Kumar et al., 2023), la evolución de los modelos de pronóstico puede clasificarse en cuatro generaciones:

La primera generación se caracteriza por el uso de modelos estadísticos tradicionales, como las series temporales y la regresión, enfocados principalmente en patrones históricos. Posteriormente, la segunda generación incorpora la inclusión de variables externas y efectos promocionales, permitiendo capturar factores adicionales que influyen en la demanda. La tercera generación introduce los modelos de machine learning, tales como Random Forest, XGBoost y redes neuronales, los cuales mejoran la capacidad predictiva al modelar relaciones no lineales complejas. Finalmente, la cuarta generación corresponde a sistemas híbridos que combinan deep learning con procesamiento contextual adaptativo, integrando múltiples fuentes de información para generar pronósticos más precisos y dinámicos.

El informe de (Deloitte, 2024a) sobre Mipymes del sector retail en América Latina indica que las empresas que implementan modelos de pronóstico de tercera y cuarta generación obtienen mejoras significativas en sus principales indicadores operativos, entre las que se destacan una reducción del inventario promedio de entre el 18% y el 25%, un incremento en la rotación del inventario que oscila entre el 15% y el 30%, una disminución de productos obsoletos estimada entre el 20% y el 35%, y una mejora en el nivel de servicio al cliente de entre el 5% y el 12%, evidenciando el impacto positivo de estas tecnologías en la eficiencia y competitividad empresarial.

Sin embargo, como advierten (Ramanathan & Muyldermans, 2023), la efectividad de estas soluciones depende no solo de la tecnología implementada, sino también de la madurez organizacional y la capacitación del personal, factores críticos para que las Mipymes puedan

aprovechar plenamente el potencial de los modelos predictivos.

Desafíos específicos del sector minorista de bebidas alcohólicas

El rubro de licorerías y tiendas de bebidas presenta condiciones particulares que hacen especialmente compleja la administración del inventario. De acuerdo con (Chen, 2024), este tipo de negocios enfrenta una alta estacionalidad, caracterizada por picos de demanda concentrados en temporadas festivas como Navidad, Semana Santa y otras celebraciones, lo que dificulta la planificación estable de la demanda a lo largo del año.

Adicionalmente, estas empresas gestionan un portafolio de productos altamente diverso, en el que coexisten artículos de rápida rotación, como cervezas y roncs de consumo masivo, con otros de rotación lenta, como vinos y licores premium. Esta heterogeneidad incrementa la complejidad del control de inventarios, ya que cada categoría presenta comportamientos de demanda y requerimientos logísticos distintos.

Otro desafío relevante es la sensibilidad promocional, dado que la demanda responde de forma inmediata a descuentos y campañas publicitarias, generando variaciones abruptas en los volúmenes vendidos. A esto se suma la limitación del espacio físico de almacenamiento, lo que obliga a realizar una planificación más precisa y eficiente para evitar tanto quiebres de stock como excesos de inventario.

Finalmente, el desempeño del negocio se ve influenciado por factores externos, tales como las variaciones en el poder adquisitivo de los consumidores y las fluctuaciones macroeconómicas, las cuales impactan directamente en las decisiones de compra y en los patrones de consumo, aumentando la incertidumbre en la gestión de inventarios.

Estos factores provocan que los modelos tradicionales sean insuficientes para capturar la complejidad de la demanda en el sector, generando tanto desabastecimientos como excesos de productos en stock. En contraste, las Mipymes que han incorporado sistemas predictivos basados en inteligencia artificial han logrado incrementar la exactitud de sus pronósticos en más de un 25% respecto a los métodos convencionales (López-Sánchez et al., 2024).

En síntesis, el contexto actual evidencia que la Licorería Josway enfrenta un escenario propicio para transitar hacia la analítica predictiva como herramienta estratégica de mejora. La adopción de un modelo de pronóstico avanzado permitirá no solo optimizar el uso de los recursos

financieros y logísticos, sino también fortalecer su capacidad de respuesta ante las variaciones del mercado, mejorando la rentabilidad y la satisfacción del cliente.

2.1 ANÁLISIS DEL MACROENTORNO

El consumo mundial de alcohol alcanzó 5.0 litros de alcohol puro per cápita en personas de 15 años o más durante 2022 (OMS, 2022) El mercado global presenta diferencias significativas entre regiones, con patrones de consumo heterogéneos influenciados por factores demográficos, culturales y socioeconómicos.

La Región de las Américas presenta el segundo consumo más alto a nivel mundial. En las Américas, el consumo anual per cápita entre personas mayores de 15 años alcanzó 8.0 litros de alcohol puro (PAHO, 2025). El consumo de América Latina de 6.5 litros de alcohol puro anualmente per cápita la posiciona como la tercera región con mayor consumo en el mundo, después de Europa con 10.1 litros y América del Norte con 9.9 litros (GAPA, 2020).

Sudáfrica representa un caso particular dentro de la región. El consumo per cápita adulto en Sudáfrica (9.5 litros) está por encima del promedio regional africano (6.2 litros) y se compara estrechamente con el de Brasil (Kasolo, 2011). El uso actual de alcohol fue reportado por 41.5% de los hombres y 17.1% de las mujeres en Sudáfrica (Peltzer et al., 2011).

India representa un mercado en expansión con características demográficas favorables para el crecimiento. El Informe de Situación Mundial sobre Alcohol y Salud 2018 de la OMS estimó un aumento del 38% en el consumo per cápita de alcohol entre personas de 15 años o más en India durante el período 2010-2017 (Balhara et al., 2022a). El consumo total de alcohol per cápita entre bebedores en India es alto, alcanzando 18.3 litros y 6.6 litros de alcohol puro para hombres y mujeres respectivamente (mayores de 15 años).

2.2 ANÁLISIS DEL MICROENTORNO (MODELO DE LAS CINCO FUERZAS DE PORTER)

El entorno competitivo del sector licorero minorista en Centroamérica presenta similitudes estructurales, pero también diferencias en digitalización, comportamiento del consumidor y políticas de mercado.

El modelo de las Cinco Fuerzas de Porter (1980) permite analizar la posición competitiva

de Licorería Josway dentro del mercado hondureño, comparándola con el contexto regional de Guatemala, El Salvador y Costa Rica.

Esta visión comparativa ayuda a identificar oportunidades estratégicas de mejora en eficiencia operativa, diferenciación de producto y adopción tecnológica.

Tabla 1: Análisis Cinco Fuerzas de Porter en el sector licorero minorista

Fuerza Competitiva	Guatemala	El Salvador	Costa Rica	Honduras (Josway)
1. Poder de negociación de los proveedores	Moderado: presencia de grandes distribuidoras regionales como Cervecería Centroamericana; acuerdos de exclusividad limitan a pequeñas licorerías (Euromonitor International, 2023).	Alto: concentración de importadores en San Salvador y dependencia de productos premium extranjeros (Banco Interamericano de Desarrollo, 2022).	Medio-bajo: mercado más formalizado y mayor competencia entre importadores (Procomer, 2023).	Medio-alto: proveedores locales controlan precios y plazos; dependencia logística genera vulnerabilidad (Secretaría de Desarrollo Económico de Honduras, 2023)
2. Poder de negociación de los compradores	Alto: el consumidor es sensible al precio y busca promociones constantes (Kantar Worldpanel, 2023).	Alto: incremento del consumo en supermercados y plataformas digitales (Comisión Económica para América Latina y el Caribe, 2023).	Medio: preferencia por marcas nacionales y experiencias de compra sostenibles (Deloitte, 2023).	Medio-alto: clientes comparan precios entre licorerías y supermercados; fidelidad depende de disponibilidad y servicio (Instituto Nacional de Estadística de Honduras, 2023).
3. Amenaza de nuevos competidores	Alta: crecimiento de tiendas de conveniencia y cadenas regionales (Euromonitor International, 2023)	Media: regulaciones municipales y licencias limitan nuevas aperturas (Ministerio de	Media-baja: mayor inversión inicial y exigencias sanitarias elevadas (Procomer, 2023).	Media: entrada de tiendas de conveniencia y plataformas de delivery aumenta la competencia local.

Fuerza Competitiva	Guatemala	El Salvador	Costa Rica	Honduras (Josway)
		Economía de El Salvador, 2023).		
4. Amenaza de productos sustitutos	Media-alta: aumento del consumo de cervezas artesanales y bebidas sin alcohol (Euromonitor, 2023).	Media: auge de bebidas energéticas y cócteles listos para beber (Mintel Group Ltd., 2023).	Alta: tendencia hacia bebidas saludables y premiumización del consumo (Deloitte, 2024).	Media: creciente demanda de cervezas artesanales y vinos jóvenes locales.
5. Rivalidad entre competidores existentes	Alta: fuerte competencia en precios y ubicación (Euromonitor International, 2023).	Alta: saturación de puntos de venta en zonas urbanas (Banco Interamericano de Desarrollo, 2022).	Media-alta: competencia basada en innovación y servicio (Procomer, 2023).	Alta: múltiples licorerías en zonas céntricas; márgenes reducidos y alta rotación.

Fuente: Elaboración propia.

Análisis Comparativo

El análisis regional muestra que los mercados de Guatemala y El Salvador presentan una alta concentración de proveedores e importadores, lo que incrementa la vulnerabilidad de las licorerías frente a variaciones de precios y disponibilidad. En contraste, Costa Rica ofrece un entorno más regulado y competitivo, donde la eficiencia operativa y la innovación tecnológica son factores diferenciadores.

En Honduras, Licorería Josway enfrenta un entorno con rivalidad intensa y alto poder de negociación de clientes, lo que obliga a diferenciarse mediante la precisión en la gestión de inventarios y el uso de modelos predictivos de demanda.

La digitalización aún incipiente en las mipymes hondureñas (Banco Interamericano de Desarrollo, 2022) representa una brecha tecnológica que puede convertirse en una oportunidad si la empresa adopta herramientas de aprendizaje automático para optimizar su abastecimiento.

Conclusión Análisis Microeconómico

El entorno competitivo centroamericano demuestra que la ventaja sostenible de las Mipymes licoreras dependerá de su capacidad para integrar analítica predictiva, gestión digital

y diferenciación de servicio.

En el caso de Licorería Josway, la adopción de un modelo de predicción de demanda y optimización de inventario le permitirá reducir la exposición a los riesgos estructurales del mercado hondureño, mejorar la rentabilidad y consolidar una posición competitiva frente a cadenas más grandes y digitalizadas.

Tabla 2 Análisis Comparativo PESTEL en la Industria Licorera Minorista

Dimensión	Honduras	Latinoamérica	India	África
Político	Fuerte impulso gubernamental a las MIPYMES mediante programas como PRONAMYPE y FOGADEP (Secretaría de Desarrollo Económico de Honduras, 2024). Sin embargo, la inestabilidad política y cambios fiscales afectan la continuidad de incentivos.	Recuperación macroeconómica post-pandemia con reducción de inflación regional a 4.2% anualizada; profesionalización de bancos centrales en Brasil, Chile y México (Banco Mundial, 2024). Persistencia de desequilibrios fiscales y deuda/PIB de 62.8% (Banco Mundial, 2024).	Políticas de liberalización del sector bebidas y fomento del "Make in India", que promueve la inversión local en productos artesanales (KPMG India, 2023).	Reformas regulatorias que promueven la formalización de pequeñas empresas y transparencia fiscal en la cadena de suministro (McKinsey & Company, 2023).
Económico	Crecimiento del PIB del 3.4% en 2023, impulsado por remesas y consumo interno (Banco Central de Honduras, 2024). Inflación y tipo de cambio afectan precios de importación.	Crecimiento proyectado de 1.9% en 2024 y 2.5% en 2025, por debajo del promedio mundial; afectado por políticas monetarias restrictivas y desaceleración de China (Banco Mundial, 2024).	Mercado de bebidas alcohólicas valuado en USD 52 mil millones, con un crecimiento anual del 8% gracias al consumo joven urbano (KPMG India, 2023).	Expansión del consumo en clase media emergente (Sudáfrica, Nigeria, Kenia), pero con alta dependencia de importaciones y volatilidad monetaria (Fondo Monetario Internacional, 2024).

Dimensión	Honduras	Latinoamérica	India	África
		Relación deuda/PIB de 62.8% limita espacio fiscal (Banco Mundial, 2024).		
Social	Consumo asociado a festividades y cultura local; tendencia hacia productos artesanales y nacionales (Instituto Nacional de Estadística, 2023).	Tendencia de moderación en consumo de alcohol con aumento del 72% de consumidores que reportan períodos de abstinencia temporal; crecimiento en segmento de bebidas premium y RTD (IWSR, 2025). Consumo per cápita de 6.5 litros de alcohol puro anual (OMS, 2018).	Tendencia hacia el consumo responsable y premiumización, con auge de bebidas de bajo contenido alcohólico y segmentos femeninos (Deloitte, 2024).	Fuerte crecimiento de microemprendimientos y consumo social urbano; preocupación por control del consumo nocivo (McKinsey & Company, 2023).
Tecnológico	Solo el 22% de las Mipymes usan herramientas digitales de gestión de inventarios o ventas (Banco Interamericano de Desarrollo, 2022). La analítica predictiva es aún incipiente.	Avances moderados en digitalización empresarial, con 45% de empresas medianas adoptando plataformas de e-commerce (BID, 2023). Brecha digital significativa en zonas rurales (CEPAL, 2024).	India lidera la digitalización minorista con integración de IA y big data en el retail (KPMG India, 2023).	Avances moderados en digitalización empresarial, con aumento de plataformas móviles de gestión de inventarios (McKinsey & Company, 2023).
Ecológico	Ley de Gestión Integral de Residuos Sólidos (Congreso Nacional de Honduras, 2023)	Compromiso regional con reducción de emisiones; 15 países implementaron impuestos al carbono	Enfoque creciente en empaques ecológicos y reducción de emisiones en la	Políticas ambientales ligadas a incentivos internacionales de sostenibilidad (Organización de las

Dimensión	Honduras	Latinoamérica	India	África
	fomenta sostenibilidad y reciclaje.	o sistemas de comercio de emisiones (CEPAL, 2023). Desafíos por deforestación y gestión hídrica.	cadena de valor (Deloitte, 2024).	Naciones Unidas, 2023).
Legal	Estricta regulación del alcohol: licencias municipales, horarios de venta y control fiscal (ISV del 15%).	Regulaciones diferenciadas por país; aumento de impuestos especiales (IEPS) en México de hasta 53% para bebidas de alta graduación (Euromonitor International, 2024). Movimiento hacia etiquetado de advertencia sanitaria (OPS, 2020).	Regulación diferenciada por estados; impulso a la trazabilidad digital de bebidas (KPMG India, 2023).	Regulaciones variables; países como Sudáfrica implementaron restricciones durante COVID-19 que permanecen parcialmente (OMS África, 2022).

Fuente: Elaboración propia.

Análisis Interpretativo

El análisis evidencia que Latinoamérica enfrenta retos vinculados con la inestabilidad política y la baja digitalización de las MIPYMES, lo cual limita la eficiencia en la gestión de inventarios y abastecimiento. En contraste, India se posiciona como un referente de transformación digital y comportamiento de consumo diversificado, impulsado por la innovación tecnológica y la creciente urbanización. Por su parte, África avanza hacia un entorno más regulado y formalizado, centrado en la transparencia operativa y la inclusión tecnológica de pequeños negocios.

Para Licorería Josway, este contraste internacional ofrece aprendizajes estratégicos clave que pueden orientar la toma de decisiones. En primer lugar, la experiencia de Latinoamérica aporta un aprendizaje de carácter operativo, al evidenciar la importancia de aprovechar las políticas públicas de digitalización y fortalecer la analítica de inventarios, con el fin de mejorar la precisión

de los pronósticos y optimizar la gestión de la demanda.

En segundo lugar, el caso de India representa un aprendizaje enfocado en la innovación, ya que resalta la necesidad de adaptar las estrategias de segmentación y diversificación del portafolio de productos en función de las tendencias de consumo emergentes, permitiendo responder de manera más ágil a mercados dinámicos y heterogéneos.

Finalmente, la experiencia de África proporciona un aprendizaje de tipo regulatorio, al subrayar la relevancia de implementar buenas prácticas de trazabilidad y cumplimiento legal, las cuales contribuyen a fortalecer la confianza del consumidor, reducir riesgos operativos y evitar sanciones, aspectos fundamentales para la sostenibilidad del negocio.

Conclusión Análisis Comparativo

El entorno macroeconómico de Licorería Josway se caracteriza por oportunidades vinculadas con la digitalización, la formalización empresarial y la diversificación de la demanda, pero también por riesgos asociados a la volatilidad política y económica. El modelo PESTEL comparativo demuestra que la competitividad del sector licorero minorista depende de la capacidad de adaptarse a las condiciones del entorno, incorporar herramientas predictivas y alinear sus prácticas con marcos regulatorios y sostenibles internacionales.

En consecuencia, la empresa debe orientarse hacia una gestión estratégica basada en datos, adoptando un enfoque analítico que le permita anticipar la demanda, reducir el sobre inventario y mantener su sostenibilidad operativa en un entorno cambiante.

2.3 CONCEPTUALIZACIÓN

Gestión de la cadena de suministro

El concepto de gestión de la cadena de suministro (Supply Chain Management) ha evolucionado desde los años 80, cuando se definía como la coordinación de flujos de materiales entre entidades de producción y distribución (Cooper, Lambert, & Pagh, 1997). Posteriormente, Lambert y Cooper (2000) ampliaron esta definición al incluir la integración de procesos desde el proveedor hasta el consumidor final, con el objetivo de generar valor en todas las etapas del flujo de bienes e información. Según el Council of Supply Chain Management Professionals (2023), la gestión de la cadena de suministro comprende “la planificación y gestión de todas las actividades involucradas en el aprovisionamiento, adquisición, conversión y logística, coordinando y

colaborando con proveedores, intermediarios y clientes, para integrar la oferta y la demanda entre empresas”. En este estudio, la gestión de la cadena de suministro se medirá a través de tres indicadores clave: el nivel de coordinación entre abastecimiento y ventas, expresado como porcentaje de pedidos planificados versus reales; el tiempo promedio de reposición, medido en días entre pedido y recepción; y la tasa de cumplimiento de entregas del proveedor, en porcentaje.

Gestión de inventarios

La gestión de inventarios se entiende como un sistema estratégico orientado a maximizar la eficiencia operativa y el retorno del capital invertido. (Silver, Pyke, & Peterson, *Inventory management and production planning and scheduling*, 2016) la definen como “el conjunto de políticas y controles que determinan cuánto, cuándo y cómo reponer el stock”. Sharma y Jain (2023) complementan que la gestión moderna busca equilibrar el nivel de servicio al cliente con los costos totales mediante decisiones algorítmicas basadas en datos de demanda actuales y proyectados. En esta investigación, la gestión de inventarios se evaluará mediante el Nivel de Servicio (Fill Rate), que indica el porcentaje de pedidos completados sin quiebre de stock; la Rotación de Inventario, que refleja el número de veces que el inventario se renueva en un periodo mensual; y el Costo de Mantenimiento de Inventario, expresado en valor monetario mensual en lempiras (L).

Modelos predictivos en la gestión de inventarios

Los modelos predictivos son sistemas algorítmicos que emplean técnicas de aprendizaje automático para analizar patrones de consumo y proyectar la demanda (Zhang & Zhao, 2022). Estos modelos integran múltiples fuentes de datos, como ventas, clima y promociones, y optimizan las decisiones de reabastecimiento mediante aprendizaje continuo. En el caso de Licorería Josway, los modelos predictivos se evaluarán con tres métricas principales: el Error Absoluto Medio (MAE), que mide el error promedio entre la demanda real y la proyectada; la Raíz del Error Cuadrático Medio (RMSE), que indica la precisión del modelo frente a variaciones bruscas; y el porcentaje de mejora del pronóstico respecto al método empírico tradicional.

Optimización del abastecimiento

La optimización del abastecimiento consiste en determinar las cantidades óptimas de productos que deben mantenerse en inventario considerando incertidumbre, costos y niveles de

servicio (Chopra & Meindl, 2018). Corsten y Gruen (2022) señalan que este proceso debe ser continuo y adaptativo, ajustando los niveles de stock según la demanda proyectada. La optimización del abastecimiento se medirá a través de la disponibilidad de producto en porcentaje, el tiempo de respuesta ante variaciones de demanda medido en horas o días, y la reducción del sobreinventario tras aplicar el modelo predictivo.

Predicción de la demanda

La predicción de la demanda se define como el proceso científico que utiliza métodos estadísticos y algoritmos de inteligencia artificial para estimar patrones futuros de consumo. Kilcourse y Rosenblum (2024) la describen como un sistema híbrido que combina datos analíticos con conocimiento humano para anticipar volúmenes y tipos de consumo. En este estudio, la predicción de la demanda se evaluará mediante la exactitud del pronóstico en porcentaje, la reducción de quiebres de stock tras la implementación del modelo, y el incremento en la disponibilidad de productos de alta rotación.

2.4 TEORÍAS DE SUSTENTO

Bases Teóricas

El presente estudio se fundamenta en un conjunto de teorías clave en analítica de negocios y gestión de inventarios, que constituyen el soporte conceptual para abordar la optimización del abastecimiento en Licorería Josway mediante modelos predictivos de demanda e inventario.

Teoría de la Gestión de Inventarios

La teoría de la gestión de inventarios establece que una administración eficiente de las existencias permite reducir costos operativos, mejorar el flujo de efectivo y asegurar la disponibilidad de productos. Autores como (Silver, Pyke, & Peterson, 2016) sostienen que el inventario no debe concebirse únicamente como un activo físico, sino como una variable estratégica que involucra decisiones sobre cuánto pedir, cuándo reabastecer y qué nivel de servicio ofrecer al cliente, considerando los costos asociados y la incertidumbre de la demanda.

Uno de los fundamentos clásicos de esta teoría es el modelo de la Cantidad Económica de Pedido (EOQ) formalizado por (Wilson, 1934) demuestra que existe un punto óptimo de reposición que minimiza el costo total de inventario, compuesto por los costos de pedido y los costos de mantenimiento. Si bien este modelo asume condiciones de demanda relativamente

estables, su relevancia persiste como base conceptual para modelos más avanzados que incorporan variabilidad y riesgo.

Investigaciones posteriores, como las de (Chopra & Meindl, 2018), amplían esta visión al señalar que, en entornos minoristas con alta volatilidad como el sector licorero, la gestión de inventarios debe orientarse a equilibrar el nivel de servicio con la eficiencia del capital de trabajo, integrando herramientas analíticas que permitan anticipar la demanda y reducir tanto los quiebres de stock como el sobre inventario.

En el contexto de Licorería Josway, esta teoría sustenta la necesidad de pasar de una gestión empírica del inventario hacia un enfoque sistemático y analítico que permita determinar niveles óptimos de stock por producto y categoría, alineados con su rotación y margen de contribución.

Teoría de la Predicción de la Demanda

La teoría de la predicción de la demanda, fundamentada por (Box & Jenkins, 1976), establecieron que la demanda futura puede modelarse a partir del análisis de patrones históricos mediante modelos de series temporales, sentando las bases de la predicción cuantitativa moderna. No obstante, estos enfoques tradicionales presentan limitaciones en mercados caracterizados por alta estacionalidad, promociones frecuentes y cambios en el comportamiento del consumidor.

Autores contemporáneos como (Zhang & Zhao, 2022) refuerzan esta perspectiva al señalar que los modelos basados en aprendizaje automático permiten identificar patrones no lineales y relaciones complejas entre variables, superando las limitaciones de los métodos estadísticos tradicionales. Desde esta teoría, la predicción de la demanda deja de ser un ejercicio meramente descriptivo para convertirse en un proceso dinámico de aprendizaje continuo.

Para Licorería Josway, esta teoría justifica la implementación de un modelo predictivo que integre información histórica con variables contextuales locales, permitiendo anticipar picos de consumo asociados a festividades, promociones o cambios estacionales, y así mejorar la planificación del abastecimiento.

Teoría de la Cadena de Suministro

La teoría de la cadena de suministro, planteada por (Lambert & Cooper, 2000), sostiene que las organizaciones deben gestionarse como sistemas interconectados donde la coordinación entre proveedores, distribuidores y puntos de venta es esencial para la eficiencia global.

La optimización del abastecimiento mediante modelos predictivos contribuye directamente a esta teoría, ya que sincroniza la demanda proyectada con el flujo de productos desde el proveedor hasta el consumidor final.

En el contexto de las Mipymes, esta integración permite reducir la incertidumbre, mejorar la comunicación con proveedores y optimizar el flujo logístico, generando una cadena de suministro más resiliente y adaptable.

Teoría de la Analítica de Negocios y Toma de Decisiones Basada en Datos

La teoría de la analítica de negocios plantea que las organizaciones que fundamentan sus decisiones en el análisis sistemático de datos logran mejores resultados operativos y estratégicos. (Davenport & Harris, 2007) introducen el concepto de *competing on analytics*, señalando que la analítica avanzada permite transformar datos en conocimiento accionable, reduciendo la dependencia de la intuición y la experiencia empírica.

En el ámbito de la gestión de inventarios, esta teoría sostiene que el uso de modelos analíticos y predictivos mejora la calidad de las decisiones al proporcionar evidencia cuantitativa sobre el comportamiento de la demanda y el desempeño del sistema. Estudios recientes muestran que las empresas minoristas que adoptan analítica predictiva logran mejoras significativas en precisión de pronósticos y eficiencia del capital de trabajo (Deloitte, 2024a).

Para el presente estudio, esta teoría respalda el enfoque metodológico adoptado y refuerza la pertinencia académica de analizar la implementación de modelos predictivos como un mecanismo de mejora continua en la gestión de inventarios de una mipyme como Licorería Josway.

2.5 ANÁLISIS DE LAS METODOLOGÍAS

Este apartado compara las principales familias de métodos aplicables a la predicción de la demanda y a la optimización del inventario en Mipymes minoristas como Josway, considerando aspectos clave como los requisitos de datos, la capacidad explicativa y el costo de implementación.

En cuanto a las familias de métodos de predicción, los métodos estadísticos clásicos, también conocidos como *base-line*, incluyen técnicas como promedios móviles, suavización exponencial (ETS) y modelos ARIMA/ARIMAX. Estos métodos son simples, rápidos y fáciles de explicar, siendo especialmente útiles cuando las series son estables y se dispone de pocos datos.

Sin embargo, presentan limitaciones frente a cambios estructurales, la incorporación limitada de variables externas y un desempeño reducido en presencia de alta no linealidad o efectos promocionales marcados. En el caso de Josway, se recomienda utilizarlos como benchmarks obligatorios y para SKUs de muy baja rotación o con series cortas, como los licores premium.

Los métodos de machine learning, por su parte, incluyen técnicas como Random Forest, Gradient Boosting (XGBoost/LightGBM), regresión regularizada (Lasso/Ridge) y k-NN. Estas técnicas permiten capturar no linealidades e interacciones complejas, por ejemplo, entre precio, temporada y evento, y funcionan bien cuando se dispone de múltiples variables externas, como clima, calendario y promociones. Su principal limitación es la mayor complejidad, ya que requieren un diseño cuidadoso de características (feature engineering) y una validación robusta. Para Josway, se recomienda su aplicación en SKUs de media y alta rotación con un horizonte semanal, integrando variables como `evento_local`, `tipo_evento`, `promoción_activa`, `temperatura`, `día_festivo`, `fin_de_mes`, `precio_relativo` y `stockout_prev`.

Finalmente, el aprendizaje profundo (Deep Learning) abarca modelos como LSTM/GRU, CNN-1D para series temporales, N-BEATS y Temporal Fusion Transformer (TFT). Estos modelos son capaces de modelar dependencias temporales complejas y múltiples series en paralelo, siendo útiles cuando se dispone de muchas series y datos suficientes. Su principal limitación es la necesidad de grandes volúmenes de datos y mayor potencia de cómputo, además de su menor interpretabilidad. En Josway, se sugiere implementarlos en piloto para familias de productos como cervezas, ron y vinos, agrupando SKUs y aplicándolos únicamente cuando se cuente con al menos 104 observaciones por serie, equivalentes a dos años de datos semanales.

Respecto a los métodos de optimización de inventario, las políticas clásicas como (s, S) y (R, Q) con demanda estocástica son fáciles de implementar y adecuadas cuando la demanda pronosticada y el lead time son relativamente estables. La optimización basada en pronósticos consiste en determinar el stock objetivo por SKU y semana, calculando el stock como la demanda esperada en el horizonte de reposición más un stock de seguridad (SS) definido por el nivel de servicio deseado, utilizando la dispersión del error del modelo (σ del residual). Por su parte, la programación heurística o híbrida prioriza SKUs considerando margen versus probabilidad de quiebre, restricciones de presupuesto y capacidad (espacio en góndola o almacén) y reglas de fill-rate por categoría.

Para la selección metodológica en Josway, se consideran los datos disponibles, que incluyen ventas POS por SKU y semana durante 24 meses, precios, promociones, calendario de eventos locales, clima, niveles de inventario y quiebres. La unidad de análisis es SKU semana, con la posibilidad de agregaciones por categoría semana para SKUs esporádicos. El horizonte de pronóstico recomendado es de 1 a 4 semanas, y las métricas de evaluación incluyen MAE, RMSE, MAPE (con precaución en valores bajos), WAPE por categoría y fill-rate simulado. La validación se realizará mediante backtesting con “rolling origin” y pruebas de Diebold Mariano para comparar modelos. Para mantener interpretabilidad, se sugiere usar SHAP o análisis de importancia de variables para explicar los factores que impactan la demanda, como eventos, promociones y clima. La decisión final consiste en implementar un ensemble que combine XGBoost con ARIMAX como baseline, junto con una política (R, Q) ajustada con stock de seguridad según el nivel de servicio deseado.

2.6 ANTECEDENTES DE METODOLOGÍAS

Diversos investigadores han desarrollado metodologías orientadas a la optimización de inventarios mediante modelos predictivos, aplicables tanto al sector retail como al comercio de bebidas y productos de alta rotación.

Modelos Estadísticos de Predicción de Demanda

Los métodos estadísticos clásicos, como los promedios móviles y la suavización exponencial, han sido ampliamente utilizados en la predicción de ventas en inventarios. Según (Boone, Ganeshan, & Hicks, 2023), estos modelos siguen siendo útiles para negocios con datos históricos consistentes, aunque presentan limitaciones ante variaciones estacionales o eventos no recurrentes.

Los modelos ARIMA, introducidos por Box y Jenkins (Box & Jenkins, 1976), han sido aplicados en el comercio minorista para estimar patrones de demanda. No obstante, su naturaleza univariante limita su capacidad para integrar variables externas relevantes, como promociones o factores económicos locales, lo que los hace insuficientes para contextos volátiles como el de las Mipymes hondureñas.

Aplicación de Machine Learning en la Gestión de Inventarios

Con los avances en analítica e inteligencia artificial, el uso de modelos de machine learning

ha demostrado resultados superiores en precisión y adaptabilidad. (Kumar, Singh, & Choudhary, 2023) destacan que algoritmos como Random Forest, XGBoost y redes neuronales pueden mejorar la exactitud de los pronósticos de demanda entre un 15% y 30% en comparación con los modelos tradicionales.

De acuerdo con (Deloitte, 2024), las empresas que adoptan técnicas de aprendizaje profundo (Deep Learning) en la gestión de inventarios han logrado reducciones de hasta un 25% en costos operativos y mejoras significativas en la disponibilidad de productos y rotación de stock.

Para Licorería Josway, estos modelos ofrecen una alternativa viable para automatizar la reposición de inventario y responder con agilidad a los cambios de demanda impulsados por eventos locales o temporadas festivas.

Optimización de Inventarios con Modelos Predictivos

Estudios recientes, como el de (López-Sánchez, García-Martínez, & Pérez-López, 2024), demuestran que la combinación de modelos predictivos y técnicas de optimización reduce los inventarios innecesarios en un 20% y mejora la disponibilidad de productos en un 18%.

Estos resultados se logran al incorporar variables contextuales como clima, promociones y comportamiento del consumidor dentro de los algoritmos predictivos. En negocios minoristas de bebidas, esta metodología permite sincronizar el inventario con la demanda real, evitando tanto el sobreabastecimiento como los quiebres de stock en los productos de mayor rotación.

Por tanto, la integración de modelos predictivos en Licorería Josway representa una herramienta estratégica para tomar decisiones basadas en datos, reducir desperdicios y mejorar la rentabilidad operativa.

En una fase más reciente, la literatura metodológica muestra un cambio sustancial hacia enfoques analíticos avanzados, donde se integran técnicas de aprendizaje automático dentro de diseños explicativos y aplicados. Estudios desarrollados en la última década evidencian que estos enfoques permiten capturar relaciones no lineales y patrones complejos de consumo que los métodos tradicionales no logran identificar. Metodológicamente, estas investigaciones adoptan esquemas de validación temporal, comparaciones cuasi experimentales y simulaciones operativas para evaluar el impacto real de los modelos en la gestión del inventario.

Un elemento metodológico común en los antecedentes más robustos es la integración de variables dinámicas y contextuales dentro del proceso de modelado. Investigaciones previas destacan que la incorporación de estacionalidad, eventos locales, promociones y comportamiento histórico del cliente no solo mejora la precisión del pronóstico, sino que fortalece la capacidad explicativa del modelo, alineando los resultados con la realidad operativa del negocio.

Así mismo, los antecedentes metodológicos más recientes no se limitan a evaluar la precisión estadística del pronóstico, sino que amplían el análisis hacia indicadores operativos y económicos, tales como quiebres de stock, sobre inventario, fill rate y eficiencia del capital de trabajo. Esta orientación metodológica resulta clave, ya que permite vincular directamente los resultados analíticos con la toma de decisiones empresariales, aspecto fundamental en contextos mipyme.

En síntesis, los antecedentes metodológicos revisados evidencian que las metodologías tradicionales resultan insuficientes para abordar problemas de abastecimiento en entornos volátiles, mientras que los enfoques predictivos basados en datos, evaluados mediante diseños longitudinales y simulaciones operativas, ofrecen una base metodológica más sólida. Este aprendizaje acumulado orienta el presente estudio a adoptar un enfoque metodológico que no solo pronostique la demanda, sino que evalúe críticamente su impacto real en la optimización del inventario de Licorería Josway.

2.7 METODOLOGÍAS, ENFOQUES Y DISEÑOS

2.7.1 METODOLOGÍA DEL ESTUDIO

En estudios tempranos sobre gestión de inventarios en pequeñas y medianas empresas, predominó el uso de metodologías cuantitativas de carácter descriptivo, enfocadas en el análisis de indicadores históricos como rotación, nivel de servicio o costos de almacenamiento. Estas investigaciones, si bien permitieron caracterizar el estado del inventario, mostraron una limitada capacidad explicativa, al no profundizar en las causas estructurales de los desabastecimientos o excesos de stock (Silver et al., 2016).

Posteriormente, investigaciones más recientes incorporaron metodologías explicativas, combinando análisis estadístico con modelación de series temporales. Estudios basados en ARIMA o suavización exponencial demostraron mejoras parciales en la precisión del pronóstico;

sin embargo, la literatura coincide en que estas metodologías presentan restricciones importantes cuando la demanda es altamente volátil o influenciada por factores externos no modelados explícitamente, como promociones, estacionalidad irregular o eventos locales (Boone, Ganeshan, & C. Hicks, 2023).

El aprendizaje metodológico clave de estos estudios es que la metodología estadística clásica resulta insuficiente por sí sola en contextos minoristas dinámicos, especialmente en Mipymes con alta variabilidad de consumo.

2.7.2 ENFOQUES Y TIPOS DE INVESTIGACIÓN

Desde el punto de vista del enfoque, la mayoría de los estudios revisados adoptan un enfoque cuantitativo, sustentado en el análisis de datos transaccionales y métricas operativas. No obstante, se observa una diferencia sustantiva entre investigaciones de enfoque meramente descriptivo y aquellas de enfoque explicativo aplicado.

Las investigaciones más robustas metodológicamente son aquellas que utilizan el enfoque cuantitativo no solo para medir resultados, sino para explicar relaciones causales entre variables predictoras y desempeño del inventario. En este sentido, trabajos recientes en analítica de negocios aplican enfoques explicativos que permiten evaluar el impacto de la incorporación de variables dinámicas sobre la precisión del pronóstico y la eficiencia del capital de trabajo (Chopra & Meindl, 2018).

El aprendizaje metodológico derivado es que el enfoque cuantitativo alcanza mayor valor científico cuando se orienta a la explicación y validación empírica, y no únicamente a la descripción de indicadores.

2.7.3 DISEÑO DE INVESTIGACIÓN

En relación con los diseños de investigación, la literatura evidencia una transición desde diseños no experimentales transversales hacia diseños longitudinales y cuasi experimentales. Estudios recientes utilizan datos históricos en ventanas temporales extendidas y aplican técnicas de validación como backtesting o particiones temporales, permitiendo comparar escenarios “antes y después” de la implementación de modelos predictivos.

Este tipo de diseño ha demostrado ser especialmente adecuado en investigaciones aplicadas al retail, ya que permite evaluar el desempeño de modelos sin intervenir directamente en la

operación real, reduciendo riesgos operativos y éticos (Syntetos et al., 2023).

El principal aprendizaje metodológico es que los diseños longitudinales con validación cuasi experimental ofrecen un equilibrio óptimo entre rigor científico y factibilidad operativa, particularmente en entornos empresariales reales.

2.8 ANÁLISIS CRÍTICO DE METODOLOGÍAS

El análisis crítico de las metodologías aplicadas en investigaciones previas sobre predicción de demanda y gestión de inventarios evidencia una evolución significativa desde enfoques estadísticos tradicionales hacia metodologías analíticas avanzadas basadas en aprendizaje automático. No obstante, esta transición no está exenta de riesgos metodológicos que, si no se gestionan adecuadamente, pueden comprometer la validez de los resultados y la aplicabilidad práctica de los modelos en contextos reales, especialmente en Mipymes del sector minorista.

Uno de los principales riesgos identificados en la literatura es el sobreajuste (overfitting), particularmente frecuente en modelos de machine learning aplicados a series temporales cortas o con alta volatilidad. Estudios recientes señalan que modelos como Gradient Boosting o redes neuronales profundas pueden mostrar reducciones de error superiores al 25% en datos de entrenamiento, pero perder hasta un 15% de precisión al evaluarse en datos fuera de muestra si no se aplican técnicas de regularización y validación temporal adecuada (Syntetos et al., 2023). En este sentido, la adopción de esquemas de validación rolling origin, early stopping y conjuntos hold-out se convierte en un requisito metodológico indispensable para garantizar la validez interna del estudio.

Otro desafío crítico se relaciona con los datos de baja rotación, característicos del sector licorero, donde muchos SKU presentan ventas esporádicas. La literatura advierte que métricas como el MAPE pueden distorsionarse severamente cuando las ventas reales se aproximan a cero, generando interpretaciones erróneas del desempeño del modelo. (Boone, Ganeshan, & C. Hicks, 2023) recomiendan sustituir estas métricas por indicadores más robustos como MAE y WAPE, o bien realizar agregaciones jerárquicas por categoría, estrategia que ha demostrado reducir el error medio por categoría en rangos del 10% al 18%.

Asimismo, las investigaciones revisadas destacan que la ausencia de registro sistemático

de promociones y quiebres de stock introduce sesgos estructurales en los modelos predictivos, ya que las ventas observadas pueden subestimar la demanda real. (Kumar et al., 2023) documentan que la omisión de estas variables puede incrementar el error de pronóstico en más del 20%, mientras que su correcta etiquetación permite mejoras significativas en la estabilidad del modelo. En consecuencia, la incorporación de variables de control y procesos de auditoría de calidad de datos se configura como una condición metodológica clave.

Desde una perspectiva de validez externa, los estudios coinciden en que los modelos predictivos desarrollados en contextos locales presentan limitaciones de generalización. Factores como clima, festividades y comportamiento del consumidor varían significativamente entre regiones, lo que obliga a reentrenar los modelos o adoptar enfoques jerárquicos si se desea replicar la metodología en otros entornos (Chopra & Meindl, 2018). Este aspecto refuerza el carácter aplicado del presente estudio y delimita su alcance científico.

En términos de robustez operativa, la literatura enfatiza la necesidad de mecanismos de detección de concept drift, especialmente ante shocks exógenos como cambios regulatorios o eventos climáticos. (Deloitte, 2024) señala que los sistemas predictivos que incorporan rutinas de reentrenamiento periódico pueden mantener niveles de precisión estables, con desviaciones inferiores al 10% incluso en escenarios de alta incertidumbre.

Finalmente, la interpretabilidad y adopción organizacional emerge como un factor crítico de éxito. Modelos percibidos como “cajas negras” tienden a ser rechazados por los usuarios finales, limitando su impacto real. Herramientas de explicabilidad como SHAP han demostrado mejorar la aceptación del sistema y la comprensión de los drivers de demanda, facilitando la toma de decisiones informadas y reduciendo la resistencia al cambio (López-Sánchez et al., 2024).

En síntesis, el análisis crítico evidencia que la solidez metodológica de un modelo predictivo no depende únicamente de la técnica empleada, sino de la correcta integración de validación estadística, calidad de datos, interpretabilidad y viabilidad operativa. Estas consideraciones fundamentan la elección metodológica del presente estudio y refuerzan su coherencia científica y práctica.

Tabla 3 :Análisis de Riesgos Metodológicos y Mitigaciones Josway

Riesgo Identificado	Descripción	Estrategia de mitigación	Indicador de control
Sobreajuste (overfitting)	Los modelos de machine learning pueden aprender ruido o patrones no generalizables en series cortas.	Aplicar validación rolling origin, regularización y early stopping; comparar rendimiento en conjunto de prueba (hold-out).	Diferencia < 5% entre error de entrenamiento y prueba (MAE/WAPE).
Datos de baja rotación	SKUs con ventas esporádicas distorsionan métricas como MAPE.	Sustituir MAPE por MAE y WAPE; agrupar por categoría o nivel jerárquico.	Error medio por categoría $\leq 15\%$.
Promociones o quiebres no registrados	La ausencia de etiquetas sesga el modelo al interpretar baja venta como baja demanda.	Etiquetar eventos de promoción y stockouts; incluir variables de control.	Porcentaje de registros correctamente etiquetados > 95%.
Cambios de precio	Las variaciones de precio pueden confundirse con cambios de preferencia del consumidor.	Usar precio relativo y elasticidades por categoría.	Coefficiente de elasticidad dentro de rango esperado (-1 a -3).
Dependencia de fuentes externas	Posible pérdida o inconsistencia de datos de clima o calendario.	Implementar variables de respaldo (fallbacks) y verificación semanal de fuentes.	Log de disponibilidad de fuentes actualizado.
Shocks exógenos (clima, regulación, economía)	Eventos imprevistos afectan la precisión y estabilidad del modelo.	Implementar detección de drift y reentrenamiento mensual/trimestral.	Alerta de drift activada < 10% de los periodos.
Interpretabilidad limitada	Modelos como GBM o DL pueden ser percibidos como “cajas negras”.	Aplicar análisis de importancia de variables y reportes SHAP.	Reporte SHAP generado por categoría/mes.
Falta de adopción por el personal	Riesgo de que los usuarios finales no comprendan las métricas o decisiones del modelo.	Capacitación en lectura de indicadores y procedimientos de reposición.	$\geq 80\%$ del personal capacitado y evaluado.

Riesgo Identificado	Descripción	Estrategia de mitigación	Indicador de control
Coste computacional	Algunos modelos (DL) demandan alto procesamiento.	Priorizar XGBoost y Random Forest; usar solo en fase avanzada.	Tiempo de entrenamiento < 1 hora por ciclo.
Restricciones físicas o presupuestarias	Limitaciones de espacio o capital afectan la aplicabilidad del modelo.	Integrar variables de capacidad y presupuesto al optimizador.	Nivel de servicio $\geq 95\%$ sin exceder presupuesto.

Fuente: Elaboración propia.

2.9 HERRAMIENTAS POR UTILIZAR

Tabla 4 Librerías y Frameworks

Librería / Framework	Función principal	Justificación comparativa
Python (Google Colab)	Lenguaje principal y entorno de ejecución.	Se seleccionó por su versatilidad, amplia adopción académica y empresarial, y disponibilidad gratuita en la nube. A diferencia de R o soluciones propietarias, Python permite integrar análisis estadístico, machine learning y automatización sin costos de licenciamiento.
Pandas	Limpieza, manipulación y estructuración de datos tabulares.	Presenta una mayor eficiencia y sintaxis intuitiva frente a alternativas como data.table (R).
NumPy	Operaciones numéricas y manejo de matrices multidimensionales.	Su integración con librerías de ML la convierte en la base de la mayoría de frameworks analíticos modernos.
Scikit-learn	Entrenamiento y validación de modelos predictivos tradicionales (Regresión, Random Forest, XGBoost).	Posee una estructura modular, documentación extensa y soporte activo en comunidad académica y empresarial.
XGBoost	Modelado predictivo basado en Gradient Boosting, ideal para datasets medianos con múltiples variables.	Supera en precisión y eficiencia a métodos clásicos (ARIMA, SARIMA) cuando se integran variables exógenas.
TensorFlow / Keras	Implementación de redes neuronales (LSTM) para proyección de series temporales.	Facilitan la creación de modelos complejos con procesamiento paralelo, superando frameworks como Theano o PyTorch en compatibilidad Colab.

Librería / Framework	Función principal	Justificación comparativa
Matplotlib / Seaborn	Visualización de resultados, métricas y patrones de consumo.	Permiten generar gráficos personalizables y reproducibles, esenciales para la comunicación de hallazgos.

Fuente: Elaboración propia.

Análisis de la Selección

El uso de Python en Google Colab se consolidó como la opción más adecuada para el desarrollo del presente estudio, al ofrecer un equilibrio óptimo entre capacidad analítica, accesibilidad tecnológica y viabilidad económica. A diferencia de herramientas visuales como KNIME no utilizadas en esta investigación, Python permite un control total sobre el proceso analítico, facilitando la validación metodológica, la replicabilidad y la transparencia científica del modelo propuesto.

Así mismo, la integración de librerías especializadas como Pandas, Scikit-learn y XGBoost permitió construir un pipeline analítico robusto, capaz de manejar datos reales con problemas habituales en Mipymes (valores faltantes, baja rotación y estacionalidad marcada). El entorno Colab eliminó la necesidad de infraestructura local, reduciendo significativamente las barreras de adopción tecnológica.

En conclusión, la elección de Python como herramienta central no solo responde a criterios técnicos, sino también estratégicos, ya que posibilita que el modelo predictivo desarrollado sea escalable, replicable y potencialmente implementable en el entorno operativo de Licorería Josway, alineándose con los objetivos de optimización del abastecimiento y sostenibilidad del negocio.

2.10 MARCO LEGAL (PROTOCOLOS, ACUERDOS, LEYES, ETC)

2.10.1 MARCO LEGAL NACIONAL

Desde el ámbito nacional, la Ley para el Fomento y Desarrollo de la Micro, Pequeña y Mediana Empresa (Decreto No. 135-2008) establece la base jurídica para la modernización de las Mipymes en Honduras. Esta normativa no solo promueve la formalización empresarial, sino que reconoce explícitamente la necesidad de incorporar herramientas tecnológicas para mejorar la productividad y competitividad. En el contexto de Licorería Josway, esta ley actúa como un

habilitador legal, ya que legitima la adopción de sistemas de análisis predictivo como una práctica alineada con las políticas públicas de innovación empresarial. Sin embargo, la ley no define lineamientos técnicos específicos, lo que obliga a la empresa a complementar su implementación con estándares internacionales para asegurar buenas prácticas.

El Código de Comercio de Honduras (Decreto No. 73-1906 y sus reformas) impone la obligación de mantener registros contables y de inventarios confiables y verificables. Desde un análisis crítico, el modelo predictivo propuesto no solo cumple esta exigencia, sino que la fortalece, al reducir errores humanos y mejorar la trazabilidad de la información histórica de ventas y existencias. No obstante, la automatización también incrementa la responsabilidad de la empresa sobre la integridad de los datos, por lo que una mala calidad de información podría derivar en incumplimientos indirectos.

En materia fiscal, el Código Tributario (Decreto No. 170-2016) y la Ley del Impuesto sobre Ventas (ISV) regulan el registro y declaración de operaciones gravadas, incluyendo la comercialización de bebidas alcohólicas. El uso de modelos predictivos no exime del cumplimiento tributario; por el contrario, exige mayor rigor en la coherencia entre inventarios, ventas y declaraciones fiscales. Desde una perspectiva crítica, la analítica predictiva puede convertirse en una ventaja para el control fiscal interno, pero también en un riesgo si se generan discrepancias entre proyecciones y registros reales.

La Ley de Regulación de Bebidas Alcohólicas (Decreto No. 365-2013) define los límites operativos del negocio en cuanto a licencias, horarios y condiciones sanitarias. El modelo predictivo debe operar dentro de estas restricciones legales, lo que implica que la optimización del inventario no puede orientarse únicamente a maximizar ventas, sino a garantizar una disponibilidad responsable del producto. Este punto resulta clave para evitar que la analítica se convierta en un incentivo indirecto al consumo excesivo.

Finalmente, en relación con la protección de datos personales, es importante señalar que en Honduras la Ley de Protección de Datos Personales (Decreto No. 69-2021) se encuentra aún en condición de anteproyecto, sin plena implementación normativa ni desarrollo reglamentario efectivo. A pesar de ello, el anteproyecto establece principios generales de confidencialidad, seguridad y uso responsable de la información, los cuales resultan pertinentes como marco orientador para investigaciones que involucran el tratamiento de datos. Desde un análisis crítico,

la ausencia de una ley plenamente vigente genera un vacío normativo que obliga a la empresa y a la investigación a adoptar voluntariamente estándares internacionales más robustos de protección de datos, con el fin de mitigar riesgos éticos, legales y reputacionales asociados al uso de analítica predictiva.

2.10.2 MARCO LEGAL INTERNACIONAL

En el plano internacional, el Reglamento General de Protección de Datos (GDPR – Reglamento UE 2016/679) se constituye como el referente más sólido en materia de protección de información personal. Aunque no es de aplicación obligatoria en Honduras, su inclusión como marco de referencia resulta pertinente desde una perspectiva ética y académica. El GDPR introduce principios como la minimización de datos, la limitación de la finalidad y la responsabilidad proactiva, los cuales fortalecen la legitimidad del uso de analítica predictiva. En el caso de Licorería Josway, adoptar estos principios reduce riesgos reputacionales y eleva el estándar de gobernanza de datos, aun cuando la legislación local no lo exija explícitamente.

Complementariamente, el marco analítico integrado de gobernanza ética de la inteligencia artificial propuesto por (Lan & Zhenjing Pang, 2022) aporta una base conceptual sólida para el uso responsable de modelos algorítmicos. Los autores advierten que los sistemas predictivos pueden amplificar sesgos existentes si no se gestionan adecuadamente a lo largo de su ciclo de vida, resaltando la necesidad de principios como la transparencia, la rendición de cuentas y la supervisión humana. En el contexto del presente estudio, estos principios se operacionalizan mediante la incorporación de mecanismos orientados a la interpretabilidad del modelo, el análisis de las variables con mayor influencia y la realización de validaciones periódicas, con el fin de evitar que la automatización derive en decisiones opacas o difíciles de justificar.

Así mismo, lineamientos internacionales como las normas ISO 27001 (seguridad de la información) y ISO 23894:2023 sobre gestión de riesgos en inteligencia artificial complementan el marco legal, proporcionando estándares técnicos que suplen las limitaciones normativas locales. Su adopción permite que la implementación del modelo predictivo se alinee con prácticas globales de seguridad, control y gestión de riesgos tecnológicos.

CAPÍTULO III. METODOLOGÍA

3.1 CONGRUENCIA METODOLÓGICA

La congruencia metodológica asegura la alineación entre objetivos, variables y métodos de análisis en este estudio. El objetivo general de diseñar un sistema de inteligencia de negocios para optimizar inventarios se operacionaliza mediante tres objetivos específicos, cada uno asociado a variables medibles (cantidad, costo, utilidad, clasificación ABC) y técnicas analíticas específicas (análisis exploratorio, pronóstico estadístico, modelos de inventario).

La metodología integra datos transaccionales históricos con modelos cuantitativos (EOQ, ROP y niveles de servicio), los cuales permiten determinar cuánto y cuándo reabastecer inventarios con el fin de minimizar costos y asegurar la disponibilidad del producto para el cliente (Heizer, Render, & Munson, 2020). Este enfoque garantiza que cada fase del estudio contribuya sistemáticamente al logro de los objetivos. La matriz de congruencia metodológica presentada en la Tabla 5 sintetiza estas relaciones, verificando la coherencia interna del diseño de investigación.

3.1.1 MATRIZ METODOLÓGICA

A continuación, se presenta la matriz para esta investigación, que sirve como un mapa conceptual de la coherencia vertical del proyecto, replicando de manera exacta los formatos PICO y SMART definidos en el Capítulo I.

Tabla 5: Matriz de congruencia metodológica

Nombre de la Investigación	Problema	Pregunta(s)de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	VARIABLES
Optimización del Inventario en Punto de Venta de Licores Mediante Modelos Predictivos de Demanda, Periodo febrero 2024 - octubre 2025	Baja adaptabilidad ante cambios del mercado: la demanda de bebidas alcohólicas varía significativamente durante celebraciones locales (como Navidad, Semana Santa o ferias municipales). Ausencia de sensibilidad estacional y promocional: los picos de demanda relacionados con promociones o campañas de marcas no son anticipados adecuadamente, generando proyecciones erróneas y sobrecostos	General En (P) la empresa Licorería Josway, ¿De qué manera la (I) implementación de un modelo predictivo multivariable basado en machine learning que integra características temporales, económicas y de producto, en (C) comparación con el sistema empírico actual de gestión manual, (O) permite reducir el error de predicción de demanda y optimizar los niveles de inventario durante el periodo febrero 2024 a octubre 2025?	General: Analizar (S) los patrones históricos de ventas en Licorería Josway mediante técnicas de machine learning y análisis descriptivo, (M) identificando los productos con mayor rotación, rentabilidad y sensibilidad, (A) a partir del procesamiento de datos reales de ventas comprendidos entre febrero de 2024 y octubre de 2025, (R) para determinar los artículos que deben mantener niveles prioritarios de stock en función de la demanda	No Experimental	Herramientas de análisis como Python y Power BI. Bases de datos históricas de ventas e inventarios Algoritmos de Machine Learning (Regresión, Series de Tiempo)	Inventarios Ventas Catálogo de Productos

Nombre de la Investigación	Problema	Pregunta(s) de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	Variables
<p>operativos.</p> <p>Gestión uniforme de productos heterogéneos: el modelo actual no distingue entre categorías con comportamientos distintos (por ejemplo, cervezas, rones populares y licores premium), impidiendo aplicar políticas diferenciadas de reposición y control según su rentabilidad o velocidad de rotación (Boone et al., 2023).</p> <p>Dependencia empírica en la toma de decisiones: ante la falta</p>	<p>Específicas derivadas</p> <p>En (P) el portafolio de productos de Licorería Josway, ¿De qué forma la (I) clasificación basada en análisis de estratos por categoría de producto, en (C) comparación con la gestión uniforme actual del inventario, (O) permite identificar los artículos con mayor criticidad de abastecimiento según su rotación y contribución a las ventas?</p> <p>En (P) los productos de alta rotación de Licorería Josway, ¿De qué forma la (I) integración de múltiples características predictoras (patrones de demanda histórica,</p>	<p>proyectada y el margen de contribución, (T) durante el periodo de investigación comprendido entre febrero 2024 y octubre 2025.</p> <p>Específicos:</p> <p>Analizar y clasificar (S) el portafolio de productos de Licorería Josway con base en su volumen de ventas, frecuencia de rotación y estabilidad de la demanda, (M) utilizando indicadores de rotación mensual y métodos de categorización ABC–XYZ para medir el comportamiento de cada producto. (A) Este análisis se desarrollará a</p>				

Nombre de la Investigación	Problema	Pregunta(s) de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	Variables
<p>de un sistema analítico, las decisiones de compra y reposición dependen del criterio del propietario o del personal de tienda. Esta subjetividad provoca variabilidad en los resultados e impide establecer estrategias consistentes de planificación</p>	<p>variables temporales y precios), en (C) comparación con proyecciones basadas únicamente en media móvil simple, (O) incrementa la precisión del pronóstico y reduce los errores de predicción (MAE y MAPE)?</p> <p>En (P) el sistema de gestión de inventarios de Licorería Josway, ¿De qué manera la (I) implementación de un modelo predictivo de demanda con técnicas de machine learning, en (C) comparación con el método empírico actual, (O) contribuye a reducir los niveles de sobre inventario y quiebres de</p>	<p>partir de los registros históricos de ventas comprendidos entre febrero de 2024 y octubre de 2025, (R) con el propósito de identificar los artículos que deben mantener distintos niveles de inventario según su criticidad comercial y aporte a la rentabilidad del negocio, (T) dentro del periodo de investigación correspondiente al año 2025.</p> <p>Evaluar (S) la contribución de múltiples características predictoras (patrones históricos de demanda,</p>				

Nombre de la Investigación	Problema	Pregunta(s) de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	Variables
		stock, optimizando la planificación de pedidos y la rentabilidad del negocio?	variables temporales y atributos de producto) sobre la precisión del pronóstico de ventas en los productos de alta rotación de Licorería Josway, mediante (M) el análisis de importancia de variables en modelos de machine learning y la comparación de métricas de error (MAE, MAPE) contra métodos tradicionales basados en media móvil, durante el periodo febrero 2024 a octubre 2025. (A) El estudio empleará técnicas de feature importance y validación estadística accesibles para una mipyme minorista, (R) con el fin de determinar qué			

Nombre de la Investigación	Problema	Pregunta(s) de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	Variables
			<p>características tienen mayor impacto en la precisión de los pronósticos de demanda y en la planificación del inventario, (T) contribuyendo a optimizar las decisiones de reabastecimiento en el transcurso del año 2025.</p> <p>Diseñar (S) un modelo de optimización de inventarios que, basado en los patrones de demanda identificados y los resultados del análisis predictivo, (M) permita comparar los niveles de stock sugeridos con los históricos de ventas y</p>			

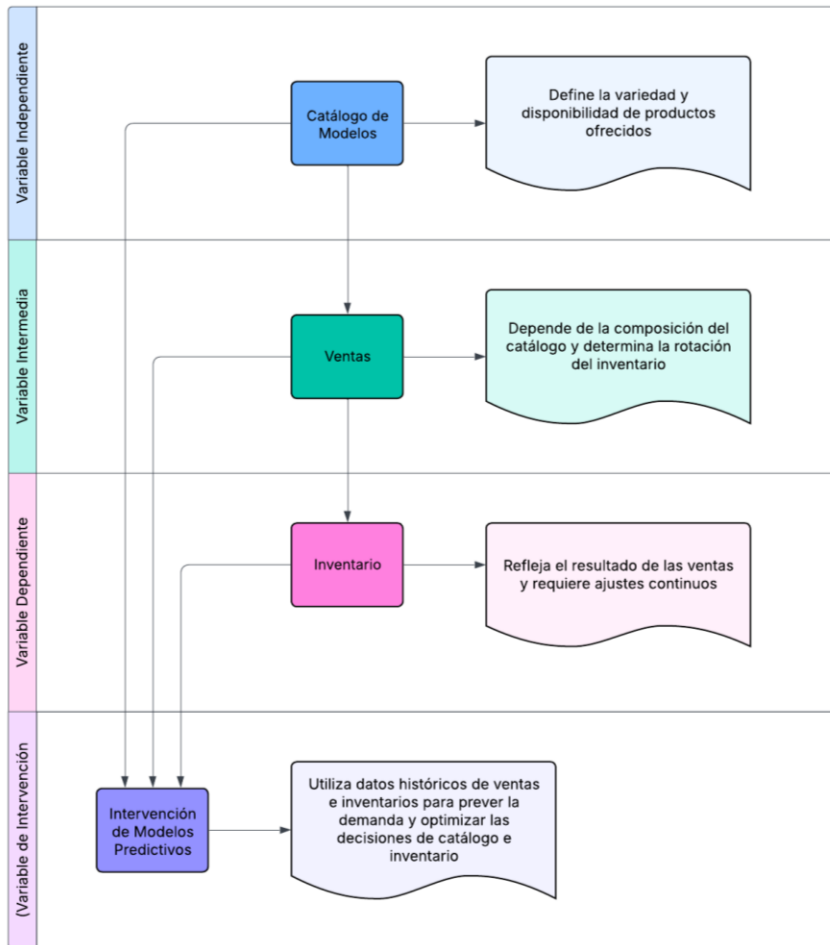
Nombre de la Investigación	Problema	Pregunta(s) de Investigación	Objetivos de la Investigación	Metodología	Instrumentos	Variables
			<p>medir su efecto en la reducción de quiebres de stock y sobre inventarios. (A) El modelo se implementará de forma experimental utilizando un subconjunto de los productos más representativos de Licorería Josway, (R) buscando maximizar la rentabilidad y la eficiencia del uso del capital de trabajo mediante una gestión predictiva más precisa, (T) aplicando la validación de resultados durante los meses finales del segundo semestre de 2025.</p>			

Fuente: Elaboración propia.

3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO

Un esquema de variables de estudio es una representación organizada de las variables objeto de la investigación muestra cómo serán relacionadas en el estudio. (Universidad de Valencia., 2020). A continuación, presentamos una explicación de las variables de estudio de nuestra investigación y como estas se relacionarán con la intervención de los modelos predictivos que utilizaremos.

Ilustración 2: Esquema de las variables de estudio



Fuente: Elaboración propia.

- **Inventario:**

- El nivel de inventario de un punto de venta está directamente afectado por las ventas realizadas. A medida que se venden dispositivos, el stock disminuye, y si no hay reposición oportuna, puede haber quiebres de stock que afecten las

ventas.

- Intervención de Modelos Predictivos: Algoritmos de predicción pueden estimar cuántas unidades de cada producto se venderán en un período determinado, permitiendo ajustar los niveles de inventario en tienda de manera eficiente.
- **Ventas:**
 - El volumen de ventas en un punto de venta está influenciado por diversos factores, como la demanda del mercado, la disponibilidad de productos y las estrategias comerciales aplicadas. Un aumento en las ventas refleja una respuesta positiva de los clientes y un adecuado manejo del surtido y la promoción, mientras que una disminución puede indicar problemas en la oferta, precios o atención al cliente.
 - Intervención de Modelos Predictivos: Los algoritmos de predicción pueden analizar patrones históricos de ventas, tendencias estacionales y variables externas para anticipar el comportamiento del consumidor. Esto permite planificar campañas comerciales, ajustar precios y optimizar la reposición de productos, asegurando una gestión más eficiente y orientada a maximizar las ventas futuras.
- **Catálogo de Modelos:**
 - El inventario de cada tienda está compuesto por los modelos disponibles en el catálogo de productos.
 - Intervención de Modelos Predictivos: Un análisis basado en datos históricos de ventas y tendencias del mercado puede optimizar qué producto deben estar disponibles en tienda.

3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES

La operacionalización de variables se refiere al proceso mediante el cual los constructos teóricos o conceptos abstractos se traducen en variables observables y medibles, posibilitando su análisis empírico dentro de una investigación. Seguidamente hacemos un desglose de las variables de operación donde explicamos su definición conceptual operacional y definimos los ítems en los que se divide cada dimensión.

Tabla 6: Matriz de Operacionalización

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Ítems
Inventario	El inventario representa el conjunto de mercancías, materias primas, productos en proceso y productos terminados que una empresa posee y mantiene para su venta o producción. Es un activo importante en el balance de una compañía que refleja los bienes que pueden ser convertidos en efectivo mediante su venta.	Valor del Inventario = Cantidad de Unidades × Costo por Unidad	Cantidad de Inventario	Unidades disponibles en stock.
				Unidades de productos de cada tipo de bien.
				Nivel de stock por categoría de producto.
			Valor del Inventario	Valor total del inventario por punto de venta
			Diversidad de Productos	Número de diferentes tipos de productos.
				Variedad de marcas o modelos por categoría.
				Disponibilidad de productos de diferentes segmentos
			Niveles de Inventario Óptimos	Niveles de inventario mínimos y máximos establecidos por cada producto
			Disponibilidad de Inventario	Productos en stock central (Bodega)
			Obsolescencia del Inventario	Edad de los productos en inventario (fecha de alta y baja de productos)
	Porcentaje de productos que ya no son comercializados o están cerca de su fecha de vencimiento			
Ventas	Las ventas	Fórmula Básica de	Volumen de	Número de unidades

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Ítems
	representan el ingreso total generado por la empresa a través de la comercialización de bienes o servicios durante un período específico. Es un indicador crucial que muestra la capacidad de una empresa para generar ingresos y su desempeño comercial.	<p>Ventas:</p> <p>Ventas = Precio de Venta × Cantidad de Unidades</p> <p>Vendidas</p> <p>Ventas Netas:</p> <p>Ventas Netas = Ventas Brutas - Devoluciones - Descuentos - Rebajas</p>	<p>Ventas</p> <p>Ventas por Producto o Categoría</p> <p>Tendencia de Ventas</p> <p>Ventas por Tipo de Cliente</p>	<p>vendidas por producto o categoría.</p> <p>Ventas totales por punto de venta</p> <p>Ventas diarias, semanales, mensuales, etc.</p> <p>Ventas por cada tipo de producto.</p> <p>Ventas por subcategoría (por ejemplo, móviles de gama alta, media y baja).</p> <p>Variación de las ventas a lo largo del tiempo (mensual, trimestral, anual).</p> <p>Identificación de patrones estacionales.</p> <p>Análisis de tendencias de ventas en fechas especiales (por ejemplo, promociones, festividades, lanzamientos de productos).</p> <p>Ventas a clientes particulares.</p> <p>Ventas a empresas o clientes corporativos.</p>
Catálogo de Modelos	Un catálogo de modelos es un documento o sistema digital que recopila y organiza de manera detallada toda la información sobre los productos o artículos de una empresa, proporcionando una descripción	Establece las especificaciones de los modelos con base a un target definido.	Especificaciones de Modelos	<p>Modelo y características</p> <p>Stock global</p> <p>Estado del producto</p> <p>Tipo de producto</p>

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Ítems
	completa de cada modelo disponible.			

Fuente: Elaboración Propia

3.1.4 HIPÓTESIS

En este estudio se formulan hipótesis que buscan comprobar si el uso de modelos predictivos mejora realmente la gestión del inventario en los puntos de venta de licores. Aunque el enfoque principal es el desarrollo y optimización de un modelo, también se incluye una etapa de comprobación estadística que permitirá verificar si los resultados obtenidos representan una mejora significativa frente al modelo tradicional empírico que utilizan los dueños del negocio.

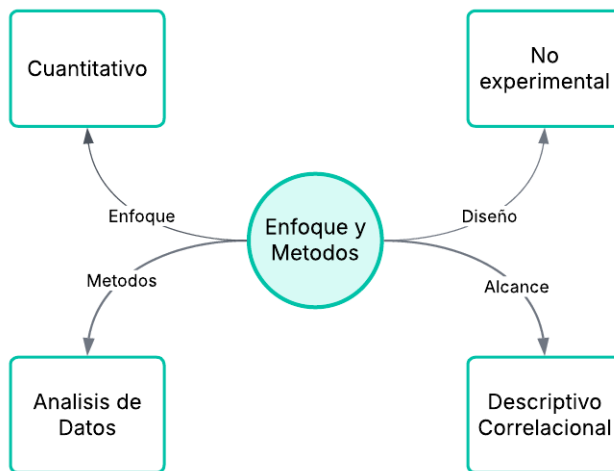
Seguidamente se establece la hipótesis orientada a analizar el impacto de la incorporación de modelos predictivos en la optimización del inventario de puntos de venta de licores JosWay:

- **Justificación:** Basado en la Teoría de la Predicción de la Demanda (sección 2.4) al combinar modelos de predicción de demanda con la administración del inventario se produjeron avances notables en la exactitud de la predicción, optimización de los costos del inventario y disminución de las quiebras de stock. Esto respalda la idea de que la inclusión de modelos predictivos optimizará la distribución del inventario y disminuirá el exceso de inventario y las faltas de productos en el punto de venta.
- **H₀:** La incorporación de modelos predictivos para el análisis de ventas no mejora las solicitudes de inventario ni reduce el desabastecimiento o exceso de stock en el punto de venta.
- **H₁:** La incorporación de modelos predictivos para el análisis de ventas mejora las solicitudes del inventario, reduciendo tanto el desabastecimiento como el exceso de stock en los puntos de venta.

3.2 ENFOQUE Y MÉTODOS

Esta investigación se basa en un modelo metodológico que permite una visualización estructurada de los métodos, el enfoque, alcance, herramientas y el diseño utilizado en la investigación, lo que simplifica la comprensión del recorrido realizado para lograr los objetivos definidos.

Ilustración 3: División de enfoque y métodos



Fuente: Elaboración propia.

Este estudio adopta un enfoque **cuantitativo**, basado en el análisis de datos históricos de ventas, inventarios y catálogo de productos, con el propósito de desarrollar un modelo predictivo que optimice la distribución de inventarios en los puntos de venta de licores. Su alcance es **descriptivo y correlacional**, ya que, por un lado, describe la situación actual del inventario y los factores que influyen en su gestión, y por otro, examina las relaciones entre variables clave como las ventas y la precisión del modelo predictivo.

3.3 DISEÑO DE LA INVESTIGACIÓN

El diseño de esta investigación es **no experimental, longitudinal, con comparación cuasi-experimental mediante backtesting**. Se considera no experimental porque no se manipulan variables de manera controlada, sino que se trabaja con datos históricos de ventas e inventarios ya existentes. Es longitudinal debido a que el análisis abarca un periodo continuo de febrero de 2024 a

octubre de 2025, lo que permite observar la evolución temporal del comportamiento de la demanda y del inventario. Asimismo, incorpora una comparación cuasi-experimental mediante backtesting, al contrastar los resultados obtenidos por el modelo predictivo con los valores reales observados en los datos históricos en el mismo periodo, con el propósito de evaluar su precisión y capacidad de optimización.

3.3.1 POBLACIÓN

La población de estudio está constituida por el historial completo de transacciones de venta registradas en la licorería exactamente 136,479 transacciones de ventas durante el período de 20 meses comprendido entre febrero 2024 y octubre 2025.

Tabla 7: Detalles de la población de estudio

Variable / Descripción	Detalle
Tamaño poblacional inicial (No)	136,479 transacciones
Marco temporal	Febrero 2024 - octubre 2025
Categorías iniciales de productos	25 categorías distintas
Productos únicos totales (SKUs)	726 códigos diferentes
Utilidad total	L. 4,152,153.46

Fuente: Elaboración propia

3.3.2 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Los criterios de inclusión y exclusión se establecen para delimitar con exactitud la muestra de los productos en inventario (SKUs) que serán sujetos al análisis por los algoritmos de optimización. El estudio de inventarios abordado por (Rekik, 2023) sugiere centrarse en productos con características específicas que generen impacto en la gestión y rentabilidad del negocio. A continuación, mostramos una tabla para explicar fácilmente estos criterios:

Tabla 8: Criterios de inclusión y exclusión

Criterios de Inclusión	Criterios de Exclusión
Pertenencia a Estrato	Ítems fuera de las categorías principales mostradas es la sección 3.3.3 Técnicas de Muestreo
Rotación Activa	Productos con cero rotaciones (ventas) en los últimos 3 meses, considerados inventario obsoleto o de baja relevancia.
Registro Histórico Completo	Productos con pocos registros de datos de ventas e historial de pedidos.
Productos de Alta Prioridad: ítems clasificados como “A” y “B”	Ítems clasificados como “C” dentro del análisis ABC (clasificación de inventarios proveniente de catálogos de productos).

Fuente: Elaboración propia.

Justificación de la inclusión: Los ítems incluidos son aquellos que permitirán la aplicación de modelos de optimización y que tendrán el mayor impacto en los resultados financieros de la empresa por su alta relevancia de clasificación.

Justificación de la exclusión: Los ítems excluidos se justifican por su irrelevancia metodológica (cero rotación o datos incompletos) o por su nulo impacto en la optimización central del negocio (materiales auxiliares).

3.3.2 MUESTRA

En esta investigación se utilizará la población luego de la aplicación de los criterios de inclusión y exclusión representados y explicados en la sección 3.3.1 y 3.3.3 respectivamente.

3.3.3 TÉCNICAS DE MUESTREO

Etapas 1: Clasificación ABC de productos

La clasificación ABC es una técnica de gestión de inventarios basada en el Principio de Pareto (regla 80 - 20), que establece que aproximadamente el 80% de los efectos provienen del 20% de las causas. En el contexto de inventarios, esto se traduce en que un pequeño porcentaje de productos genera la mayoría del volumen de ventas o valor del inventario (MrPeasy, 2023).

La clasificación ABC divide el inventario en tres categorías:

Tabla 9: Clasificación ABC en inventarios

Clase	% Productos	% Valor Acumulado	Descripción	Estrategia de Gestión
A	10 – 20 %	70 – 80 %	Vitales - Alta rotación	Control estricto, revisión frecuente
B	20-30%	15-25%	Importantes - Media rotación	Control moderado, revisión periódica
C	50-70%	5-10%	Triviales - Baja rotación	Control básico, revisión esporádica

Fuente: Tomada de (*MrPeasy, 2023*)

Se verifica la aplicación del principio de Pareto de la siguiente forma:

Tabla 10: Clasificación de productos pareto licorería JosWay

Clase	N° Productos	% Productos	Utilidad Recibida L.	% Utilidad
A	52	7.16%	L.3,312,478.75	79.78%
B	143	19.69%	L.631,549.10	15.21%
C	531	73.14%	L.208,125.61	5.01%
Total	726	100%	L.4,152,153	100%

Fuente: Elaboración propia.

La clasificación ABC evidencia que un 7.16% de los productos (Clase A) generan el 79.78% de la utilidad, confirmando el principio 80-20. Al considerar las clases A y B, que representan el 26.85% de los productos, se concentra el 94.99% del volumen total, lo que justifica priorizar estos grupos en el análisis. En contraste, la Clase C, que abarca el 73.14% de los productos, aporta solo el 5.01% del volumen, por lo que se considera de baja prioridad estratégica.

Etapa 2: Rotación Activa

Se consideraron únicamente los productos con al menos una venta en los últimos 90 días (al 25 de octubre de 2025), garantizando que los datos reflejen una rotación vigente. El periodo de 90 días se utiliza por su representatividad temporal (equivale a un trimestre), su coherencia con los

horizontes de predicción de 1 a 3 meses en sistemas de BI y por ser un estándar común en el sector retail de productos de consumo rápido (FMCG).

Tras el análisis de rotación activa 18 productos (9.47%) no cumplen pues no presentan ventas en los últimos 90 días, dando un total de 172 productos incluidos tras esta etapa representando el 98.36% de Etapa A+B, y una pérdida de L.64,599.23 en la utilidad generada siendo este solo el 1.64% del total.

Etapa 3: Historial Completo

Se consideraron únicamente los productos con al menos 10 transacciones registradas en todo el historial. Este umbral garantiza una base mínima de datos confiable para el entrenamiento de modelos de Machine Learning, permite la aplicación válida de cálculos estadísticos pues al exigir al menos 10 transacciones por producto busca que haya suficiente información para que los cálculos del modelo predictivo y las métricas estadísticas sean válidos y consistentes, reduciendo el efecto del azar según el Teorema del Límite Central (Levin, 2017) y ayuda a distinguir patrones reales de la variabilidad aleatoria.

Solo 4 productos fueron excluidos por tener menos de 10 transacciones, lo que representa una pérdida marginal de utilidad L.7,676 correspondiente al 0.20%.

Tabla 11: Clasificación de estratos

Estrato	Productos únicos	Transacciones	Utilidad Total
Cerveza Internacional	9	88	4,913.66
Cerveza Nacional	10	89	2,719.01
Tabaco	15	86	909.26
Snack	20	47	433.08
Licor	12	38	1,502.95
Otros	9	35	565.38

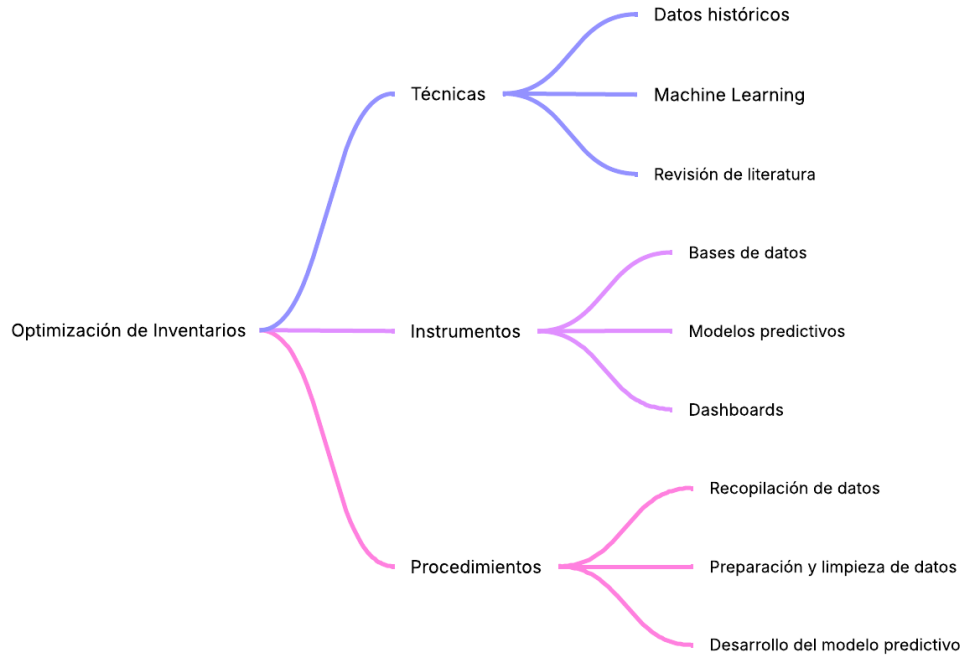
Fuente: Elaboración propia.

3.4 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS

Seguidamente presentamos una visión integral que abarca desde la recopilación y análisis de datos históricos hasta el desarrollo y validación de modelos predictivos, con el objetivo de garantizar una gestión eficiente y precisa del stock. La estructura metodológica expuesta refleja el enfoque

sistemático para asegurar la calidad y aplicabilidad de los resultados obtenidos en el estudio.

Ilustración 4 Diagrama de subdivisión de técnicas



Fuente Ilustración 6: Elaboración propia.

3.4.1. TÉCNICAS DE ANÁLISIS

- **Análisis de datos históricos:**
 - ¿Que se realizara?: Se recopilaran y analizaran registros de ventas, inventarios, catálogos.
 - ¿Por qué se realizará?: El análisis exploratorio y descriptivo de los datos históricos constituye la base para entender patrones de demanda, estacionalidad y comportamiento de rotación por producto, paso imprescindible antes de construir modelos predictivos y reglas de reposición. (Turkmen, 2024) señala que el análisis inicial de series históricas y atributos de producto es necesario para seleccionar características relevantes y detectar patrones temporales que impactan la predicción de la demanda.

- **Modelado predictivo:**

- ¿Que se realizara?: Se aplicaran algoritmos de aprendizaje automático (Machine Learning) y series de tiempo para estimar la demanda futura de inventarios basados en ventas.
- ¿Por qué se realizará?: Revisiones recientes muestran que los enfoques basados en ML (incluyendo ensamblados y redes neuronales) suelen mejorar la precisión de pronóstico en entornos comerciales, aunque la elección final depende de las características de la serie (estacionalidad, volatilidad, datos por SKU). Por ello se probarán al menos tres algoritmos representativos y se compararán con métodos de referencia. (Douaioui, 2024).

3.4.2. PROCEDIMIENTOS

- **Recopilación de datos:** Se obtuvieron datos históricos de ventas, inventarios y tránsitos desde los sistemas de la empresa.
- **Preparación y limpieza de datos:** Se realizará un preprocesamiento para eliminar valores atípicos, datos faltantes y variables irrelevantes.
- **Desarrollo del modelo predictivo:** Se probarán 3 algoritmos de Machine Learning para encontrar el más preciso.
- **Validación del modelo:** Se evaluará el desempeño con métricas de precisión del modelo.
- **Implementación y visualización:** Se creará un dashboard interactivo para el monitoreo de predicciones y stock, se documentarán los resultados y se presentarán recomendaciones para optimizar la distribución de inventarios.

3.5 FUENTES DE INFORMACIÓN

El desarrollo de esta investigación se sustenta en la utilización de fuentes de información que permiten construir una base de datos sólida y confiable para el análisis. La combinación de registros internos del negocio y de literatura especializada garantiza tanto la validez empírica como el respaldo teórico del estudio. En este sentido, se emplean datos de origen primario utilizados como fuentes

secundarias provenientes de los sistemas internos de la empresa, así como fuentes secundarias externas conformadas por investigaciones académicas y publicaciones científicas relacionadas con la predicción de demanda, la gestión de inventarios y la aplicación de técnicas de *Machine Learning* en entornos empresariales.

Estas fuentes proporcionan los insumos necesarios para el diseño, desarrollo y validación del modelo predictivo propuesto, asegurando que el estudio cuente con un soporte metodológico y conceptual adecuado.

3.5.1 FUENTES DE DATOS PRIMARIAS

No se utilizaron fuentes de datos primarias.

3.5.2 FUENTES SECUNDARIAS

Las fuentes secundarias complementan el análisis empírico mediante la revisión de literatura científica y técnica. Esta revisión proporciona el sustento teórico y metodológico del estudio, al identificar enfoques, modelos y técnicas utilizadas en investigaciones previas sobre predicción de demanda y optimización de inventarios.

Asimismo, los estudios académicos y publicaciones especializadas relacionadas con la aplicación de *Machine Learning* en la gestión de la cadena de suministro permiten comparar metodologías, validar criterios analíticos y contextualizar los resultados obtenidos en este trabajo dentro de un marco conceptual sólido y actualizado.

3.6 PLAN DE ANÁLISIS

Tabla 12: Análisis de Tiempos

Fase	Actividad Clave	Entregable	Duración Estimada	Cronograma (Semanas)
1. Diagnóstico y Muestra	1.1. Recopilación de datos de ventas (últimos 12 meses).	Base de Datos Histórica y Financiera.	1 semanas	Semana 1
	1.2. Aplicación de Clasificación ABC y estratificación.	Lista de SKUs seleccionados para la		

Fase	Actividad Clave	Entregable	Duración Estimada	Cronograma (Semanas)
		Muestra Estratificada.		
2. Modelamiento de la Demanda	2.1. Pronóstico de la demanda futura por SKU dentro de la muestra. 2.2. Cálculo del Stock de Seguridad y Nivel de Servicio por estrato.	Modelo de Pronóstico de Demanda.	3 semanas	Semanas 2-4
3. Optimización y Propuesta	3.1. Cálculo del Lote Económico (EOQ) y Punto de Reorden (ROP) por SKU. 3.2. Formulación de la Política de Inventario Óptima por estrato.	Valores de EOQ y ROP óptimos. Propuesta de Nueva Política de Inventario.	2 semanas	Semanas 5-7
4. Conclusiones y Resultados	4.1. Análisis Comparativo (Costo Actual vs. Costo Optimizado). 4.2. Redacción de Conclusiones y Recomendaciones.	Informe Final de Resultados (Ahorros o Mejora de Nivel de Servicio cuantificados).	1 semana	Semana 8

Fuente: Elaboración propia

La Tabla 12 muestra el plan de análisis, que organiza el progreso de la investigación en cuatro etapas consecutivas. Estas fases posibilitan avanzar de forma ordenada desde la recopilación de datos hasta que se formulan las conclusiones y propuestas.

La etapa inicial, llamada **Diagnóstico y Muestra**, comienza con la recopilación de datos históricos de ventas e inventarios durante el último año y con el uso del método ABC de clasificación para determinar los productos más importantes en relación con el valor y a las rotaciones. Esta fase termina con la creación de una muestra estratificada de SKU, lo que asegura un fundamento firme y representativo para el análisis subsiguiente.

La segunda etapa, **Modelamiento de la Demanda**, se enfoca en crear modelos predictivos que calculen la demanda futura de cada producto. Aquí se lleva a cabo la estimación por SKU y el cálculo del stock de seguridad y el nivel de servicio para cada categoría, lo que demora aproximadamente tres semanas. Esta etapa representa el centro analítico de la investigación, dado que posibilita prever las necesidades de inventario y justificar las resoluciones de reposición.

La etapa número tres, llamada **Optimización y Propuesta**, convierte los hallazgos del modelado en decisiones específicas de carácter operativo. Se determinan los puntos de reorden (ROP) y los lotes económicos de pedido (EOQ) ideales para cada producto, y se elabora una sugerencia de política de inventario que se adapta a las características específicas de cada categoría.

Por último, la cuarta etapa, **Conclusiones y Resultados**, incluye un análisis comparativo entre el estado actual y la propuesta optimizada, enfatizando los posibles avances o ahorros en el nivel del servicio. Asimismo, se elaboran las recomendaciones y conclusiones que condensan los descubrimientos del estudio.

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

Los datos compartidos por Licorería Josway representan un histórico detallado de sus ventas y facturación. Básicamente, es información que nos muestra cómo ha funcionado el negocio desde el punto de vista comercial y financiero, mezclando números concretos con características del producto. Para este análisis nos enfocamos principalmente en cuatro aspectos clave: cuánto venden, cuánto les cuesta, a qué precio lo ofrecen y cuánto ganan con cada venta.

El volumen de ventas es considerable: Hablamos de más de 876 mil unidades vendidas. El negocio invirtió alrededor de L.4 millones en costos, generó ventas por más de L.5.3 millones y obtuvo ganancias cercanas a los L.3.9 millones. Esto nos dice que la licorería está funcionando bien y que sabe manejar sus costos de manera eficiente.

Algo interesante ocurre cuando miramos los promedios: en cada transacción se venden en promedio 7.5 unidades, pero la mayoría de las ventas son de apenas 2 unidades. ¿Qué significa esto? Que, aunque la mayoría de las veces venden poco, hay ocasiones en las que venden cantidades enormes que suben ese promedio. Lo mismo pasa con los precios: El precio promedio es de L.45.80, pero la mitad de los productos se venden a L.25.00 o menos. Esto tiene mucho sentido si pensamos que en la licorería conviven productos baratos como cervezas y gaseosas con licores importados o de alta gama. Claramente tienen dos tipos de clientes muy distintos: Los que compran al detalle y los que compran al por mayor.

Los números también nos muestran que hay mucha variación en las ventas. De hecho, la dispersión es bastante alta, con coeficientes que superan el 200% en todos los casos. Esto es normal en un negocio como este, donde un día puedes vender unas cuantas cervezas y al siguiente surtir un evento completo.

Si analizamos cómo se distribuyen estos datos, vemos que están muy sesgados: hay muchísimas ventas pequeñas y muy pocas ventas grandes. Además, encontramos valores extremos que se salen de lo común, tanto en cantidades vendidas como en precios y márgenes de ganancia. Por ejemplo, hay ventas desde media unidad hasta 4,800 unidades, precios que van desde L.0.50 hasta L.1,500.00, y ganancias que oscilan entre una pérdida de L.1,670 hasta una utilidad de más de L.8,400. Estas cifras tan dispares confirman que la licorería maneja productos muy variados y que a veces tiene operaciones especiales o promociones.

En resumen, lo que encontramos es un negocio con dos caras: por un lado, un flujo constante de ventas pequeñas y cotidianas, y por otro, ventas esporádicas pero muy grandes que impactan significativamente en las ganancias totales. Esta combinación genera mucha variabilidad en los datos, lo cual nos indica que más adelante será necesario limpiar la información, identificar esos casos excepcionales y ajustar los números para poder hacer análisis más precisos.

4.1 ANÁLISIS EXPLORATORIO DE DATOS (EDA)

4.1.1 DESCRIPCIÓN GENERAL DEL CONJUNTO DE DATOS

Tabla 13 Métricas Generales

Métrica	Descripción	Valor
Total de registros (transacciones)	Número total de observaciones registradas en el sistema de ventas.	116,83
Facturas únicas	Total de comprobantes distintos asociados a las transacciones.	75,43
Productos únicos (SKUs)	Total de productos diferentes comercializados.	177
Estratos definidos	Niveles o categorías de producto definidos en la base de datos (por ejemplo: Cerveza Nacional, Cerveza Internacional, Refrescos, Tabaco, Snacks, Licores).	6

Fuente: Elaboración propia.

Interpretación:

- El conjunto de datos está conformado por 116,830 registros, lo que representa un volumen de información robusto y estadísticamente significativo para realizar un análisis exploratorio y descriptivo confiable.
- Las 75,430 facturas únicas indican que una parte importante de las ventas contiene múltiples productos por transacción, lo que permite analizar tanto la frecuencia de compra como la diversidad de artículos vendidos por cliente.
- Con 177 productos únicos, la base de datos refleja un portafolio comercial variado, con productos de distinta naturaleza y nivel de precio.
- Los 6 estratos definidos agrupan los productos en categorías amplias (como cervezas,

refrescos, tabaco, snacks y licores), lo que facilita la segmentación del análisis según tipo de producto o comportamiento de mercado.

En conjunto, la estructura del conjunto de datos de Licorería Josway permite un análisis integral de las operaciones de venta, tanto a nivel general como por categoría, garantizando la representatividad y profundidad de los resultados obtenidos.

Las variables analizadas en el estudio se dividen en cuantitativas y cualitativas. Las variables cuantitativas, de tipo continuo o discreto, incluyen la cantidad, entendida como las unidades vendidas por transacción; el costo, correspondiente al costo unitario del producto expresado en lempiras; el precio de venta, que representa el precio unitario de venta en lempiras; y la utilidad, definida como la ganancia generada por cada transacción, también en lempiras.

Por su parte, las variables cualitativas, de tipo categórico o nominal, comprenden la fecha de la transacción, el número de factura como identificador único, el producto (nombre del artículo), el código o SKU del producto, la categoría ABC (A, B o C), la categoría original del producto, los estratos utilizados en el muestreo estratificado y la rotación, como indicador de rotación activa. Adicionalmente, se analizaron las características básicas de los datos, tales como rangos, promedios y frecuencias, con el fin de describir el comportamiento general de las variables y apoyar el análisis posterior.

Tabla 14 Estadísticas Generales

Variable	Media	Mediana	Rango (Mín – Máx)	CV (%)	Suma total
Cantidad	7.50	2.00	0.00 – 4,800.00	429.29	876,488.07
Costo (L)	34.23	20.08	0.00 – 1,211.40	212.03	3,999,474.12
Precio Venta (L)	45.80	25.00	0.50 – 1,500.00	215.61	5,350,464.53
Utilidad (L)	33.21	13.65	-1,669.99 – 8,435.52	219.82	3,879,428.62

Fuente: Elaboración Propia

Interpretación:

- Las medias son considerablemente mayores que las medianas, lo cual muestra alta asimetría positiva: la mayoría de las ventas son pequeñas, pero existen operaciones de alto valor que elevan los promedios.

- Los coeficientes de variación ($CV > 200 \%$) reflejan una gran dispersión y heterogeneidad entre las transacciones.
- Los rangos amplios confirman que la empresa realiza tanto ventas al detalle (bajos valores) como al por mayor (valores muy altos).

Los datos presentan una estructura limpia, sin valores faltantes, pero con alta variabilidad y presencia de valores extremos propios de la naturaleza comercial del negocio. Estas características justifican la aplicación de técnicas de normalización o estandarización en etapas posteriores para garantizar un análisis más homogéneo y representativo.

4.1.2 LIMPIEZA Y PREPARACIÓN DE LOS DATOS

- **Detección y manejo de valores atípicos (outliers).**

Tabla 15 Interpretación Valores Atípicos

Variable	Cantidad de outliers	Porcentaje total	Interpretación	Acción
Cantidad	15,420	13.20%	Ventas con cantidades muy grandes o pequeñas. Refleja diferencias entre clientes minoristas y mayoristas.	No se tomarán cantidades menores a 1
Costo	12,204	10.45%	Productos con precios de compra anómalamente bajos o altos (por ejemplo, promociones o artículos premium).	No se tomarán costos menores a L.1 que no sean del Estrato SNACK
Precio Venta	12,423	10.63%	Variaciones amplias en los precios de venta, probablemente por descuentos o distintos tipos de bebidas.	Se mantendrán los valores
Utilidad	8,903	7.62%	Transacciones con ganancias o pérdidas inusuales (descuentos, errores de facturación o ventas especiales).	Se mantendrán los valores

Fuente: Elaboración Propia.

Interpretación conforme a los Outliers:

- 1) Entre el 7 % y el 13 % de las transacciones presentan valores atípicos, lo que indica una alta dispersión en las operaciones.
- 2) La variable con más outliers es “Cantidad”, lo que sugiere una mezcla clara de ventas minoristas (1–5 unidades) y ventas por volumen (decenas o miles de unidades).
- 3) Los outliers de costo y precio de venta reflejan la amplitud del catálogo: desde productos de bajo valor (Cervezas nacionales) hasta bebidas importadas o premium.

Tratamiento de datos faltantes o inconsistentes.

Durante la etapa de limpieza del conjunto de datos de Licorería Josway, se realizó un proceso sistemático para verificar la existencia de valores faltantes, nulos o inconsistentes en todas las variables. Los resultados mostraron que no se registraron datos faltantes en ninguna de las 13 columnas que componen la base (es decir, 0 valores nulos).

Esto evidencia que el archivo cuenta con una estructura de datos completa y bien mantenida, lo cual facilita la fiabilidad del análisis y reduce la necesidad de imputación.

No obstante, el examen exploratorio permitió identificar valores inconsistentes o extremos, principalmente en las variables CANTIDAD y COSTO mencionadas en la Tabla 15, estas inconsistencias de cantidades y costos menores a una unidad serán excluidas de la data set final, quedando como resultado después de la limpieza **110,916** transacciones eliminando así 5,914 filas, explicadas en los siguientes datos:

Tabla 16: Estadísticas Generales sin outliers

Variable	Media	Mediana	Rango (Mín – Máx)	CV (%)	Suma total
Cantidad	7.67	2.00	1.00 – 4,800.00	430.21	876,488.07
Costo (L)	36.02	20.48	1.00 – 1,211.40	205.60	3,999,474.12
Precio Venta (L)	48.15	26.00	1.42 – 1,500.00	209.29	5,350,464.53
Utilidad (L)	34.87	315.17	–1,669.99 – 8,435.52	213.75	3,879,428.62

Fuente: Elaboración Propia.

Como vemos en la Tabla 18 el Coeficiente de Variación (%) es superior al 100% lo que indica que los datos tienen una gran variabilidad en relación con su media. Esto sugiere que la media por sí sola puede no ser una buena representación del conjunto de datos y que hay mucha dispersión. Por ejemplo, en tus datos de CANTIDAD, el CV% es 430.21%, lo cual es muy alto e indica una dispersión extrema.

Normalización o estandarización de los datos.

En la investigación se observan rangos de valores muy diferentes en las variables cuantitativas como ser CANTIDAD, COSTO, PRECIO VENTA y UTILIDAD (por ejemplo, CANTIDAD puede ir de 1 a 4,800, mientras que COSTO de 1 a 1,211). Muchos algoritmos de Machine Learning son sensibles a las escalas de las características. Si una variable tiene un rango de valores mucho mayor que otra, podría dominar el cálculo de la distancia o la importancia en el algoritmo, lo que llevaría a resultados sesgados.

La normalización (**Min-Max Scaling**) reescala los datos de cada característica a un rango fijo, generalmente entre 0 y 1, asegurando que todas contribuyan por igual a la distancia o la importancia sin importar su magnitud original, mientras que la estandarización (**Z-Score Standardization**) transforma los datos para que tengan una media de 0 y una desviación estándar de 1, siendo útil cuando no se desea limitar el rango de los valores, pero sí mantener una escala similar entre las variables.

La normalización se utiliza en este estudio porque contribuye significativamente a mejorar el rendimiento de diversos algoritmos de aprendizaje automático. En primer lugar, los algoritmos basados en gradientes como la regresión logística, las redes neuronales y las máquinas de vectores de soporte presentan una convergencia más rápida y estable cuando las características se encuentran en una escala similar. Asimismo, los métodos que dependen del cálculo de distancias, como K-Nearest Neighbors (KNN) o K-Means, requieren que todas las variables tengan rangos comparables, de modo que ninguna característica con valores elevados influya de manera desproporcionada en la medición de distancias.

Finalmente, aunque la normalización no elimina los valores atípicos, sí reduce su impacto, permitiendo que algunos algoritmos trabajen con mayor estabilidad al mantener dichos valores dentro de un rango más controlado.

Tabla 17 Normalización y Estandarización de los Datos

Variable	Rango (mín máx)	Escala Original	Escala tras Estandarización (Z-score)	Escala tras Normalización (Min-Max)	Interpretación
Cantidad	1.00 – 4,800.00	Mean: 7.67 Std: 33.01	Mean: 0 Std: 1	Mean: 0.06 Std: 0.01	Presenta alta dispersión, es decir, ventas pequeñas y mayoristas de gran volumen.
Costo (L)	0.00 – 1,211.40	Mean: 34.23 Std: 72.58	Mean: 0 Std: 1	Mean: 0 Std: 0.06	Variabilidad elevada en productos económicos y artículos premium.
Precio Venta (L)	0.50 – 1,500.00	Mean: 45.80 Std: 98.374	Mean: 0 Std: 1	Mean: 0.03 Std: 0.07	Amplia dispersión; refleja la mezcla de precios en el catálogo.
Utilidad (L)	-1,669.99 – 8,435.52	Mean: 33.21 Std: 72.99	Mean: 0 Std: 1	Mean: 0.17 Std: 0.01	Muestra transacciones con ganancias y pérdidas excepcionales

Fuente: Elaboración Propia.

Interpretación:

- La presencia de rangos extensos y desviaciones estándar elevadas en las variables motivó la implementación de procedimientos de reescalamiento para homogeneizar los datos.
- Mediante la aplicación de la estandarización por puntuación Z, se logró transformar todas las variables a una escala común con promedio cero y desviación típica unitaria, facilitando así su comparación bajo criterios uniformes.
- El proceso de normalización Min-Max permitió comprimir la totalidad de los valores dentro del intervalo cerrado [0,1], resultando particularmente útil para la elaboración de representaciones gráficas y la implementación de modelos analíticos susceptibles a diferencias de escala.
- Estos métodos de transformación neutralizan el efecto de las distintas magnitudes y unidades de medición (tales como unidades físicas y moneda local), preservando al mismo tiempo tanto la estructura distribucional de los datos como las relaciones de dependencia entre las variables estudiadas.

Los percentiles analizados revelan que las variables cuantitativas exhiben distribuciones asimétricas y con valores extremos, especialmente en COSTO, PRECIO VENTA y UTILIDAD. Esto justifica el uso de técnicas como la normalización y respalda la necesidad de métodos estadísticos robustos para el análisis posterior. Además, la concentración de valores bajos en CANTIDAD indica que la mayoría de las transacciones corresponden a compras pequeñas, lo cual es relevante para la interpretación del comportamiento del cliente y la posterior segmentación.

Tabla 18: Percentiles de las variables cuantitativas

Percentil	Cantidad	Costo	Precio Venta	Utilidad
P10	1.00	3.14	5.00	5.04
P25	1.00	14.58	22.00	7.92
P50	2.00	20.48	26.00	15.17
P75	6.00	27.80	35.00	41.34
P90	20.00	49.03	60.00	77.73
P95	24.00	143.14	200.00	113.96
P99	48.00	399.99	520.00	255.04

Fuente: Elaboración Propia.

Interpretación:

- **Cantidad:** presenta una distribución **sesgada hacia valores pequeños**, con pocos casos extremos.
 - Entre el P10 y el P25, la cantidad se mantiene en 1 unidad, indicando que al menos el 25% de los registros corresponden a ventas muy pequeñas.
 - En P50 (mediana) la cantidad es solo 2 unidades, lo que confirma que la mitad de las observaciones representan compras reducidas.
 - Recién a partir de P75 se observa un incremento a 6 unidades.
 - El P99 alcanza 48 unidades, mostrando que existen transacciones inusualmente grandes, pero representan una proporción muy baja del total.
- **Costo:** El costo muestra una distribución sesgada a la derecha, con algunos productos de costo muy elevado que influyen en el extremo superior.
 - El P10 inicia en 3.14, pero ya en P75 asciende a 27.80, indicando un aumento progresivo.
 - El P95 llega a 143.14, y el P99 alcanza 399.99, lo cual evidencia la presencia de valores outliers o artículos de muy alto costo.
- **Precio Venta:** Presenta una alta variabilidad, con un pequeño porcentaje de elementos muy costosos.
 - P10 = 5.00 y P50 = 26.00, lo que indica un crecimiento uniforme en la mitad inferior de la distribución.
 - El salto entre P75 (35.00) y P95 (200.00) es considerable, mostrando variaciones fuertes en precios entre productos comunes y productos de nicho o de alta categoría.
 - En P99 se observa un precio de 520.00, confirmando la existencia de outliers.
- **Utilidad:** La utilidad refleja un patrón similar al de Costo y Precio.
 - En los percentiles inferiores, los valores crecen de manera moderada.
 - El P75 se ubica en 41.34, pero el P95 sube abruptamente a 113.96.
 - En el P99 llega a 255.04, lo que indica que algunas ventas generan utilidades excepcionalmente altas, aunque son muy poco frecuentes.

4.1.3 ANÁLISIS DE DESCOMPOSICIÓN DE SERIES DE TIEMPO


Previo al desarrollo de los modelos predictivos, se realizó un análisis de descomposición temporal de las ventas mensuales agregadas para identificar los componentes estructurales de la demanda. La descomposición se realizó mediante el método aditivo clásico, expresado como:

$$Y(t) = T(t) + S(t) + R(t)$$

Donde $Y(t)$ representa las ventas totales en el mes t , $T(t)$ el componente de tendencia, $S(t)$ el componente estacional y $R(t)$ el componente residual.

La serie temporal analizada comprende 21 meses (febrero 2024 - octubre 2025) con ventas totales mensuales promedio de 40,527 unidades, máximo de 67,141 unidades y mínimo de 22,388 unidades. La Ilustración 5 presenta la descomposición completa en sus cuatro componentes.


Ilustración 5: Representación de tendencias en la información de JosWay



El análisis del componente de tendencia mediante regresión lineal reveló un patrón CRECIENTE con pendiente de +1,343.36 unidades por mes, proyectando un crecimiento anual de aproximadamente 16,120 unidades. El coeficiente de determinación $R^2 = 0.9885$ del ajuste lineal indica que la línea de tendencia explica el 98.85% de la variabilidad del componente de tendencia, confirmando un crecimiento sostenido y consistente.

Este crecimiento es atribuible a la expansión del negocio durante el período analizado, reflejando tanto el aumento en la base de clientes como la incorporación de nuevos productos al portafolio. La identificación de esta tendencia alcista valida el uso de features LAG (LAG_1_CANTIDAD, LAG_2_CANTIDAD, LAG_3_CANTIDAD) en los modelos predictivos, ya que las ventas de meses recientes son predictores relevantes del comportamiento futuro en un contexto de crecimiento sostenido.

Ilustración 6: Representación gráfica de estacionalidad



Se identificó un patrón estacional significativo con período de 10 meses y una amplitud de 18,522 unidades, representando una variación de $\pm 22.9\%$ respecto a la media histórica. Los meses de mayor demanda son:

- Mayo: +5,385 unidades (+13.3% sobre tendencia)
- Junio: +5,164 unidades (+12.7% sobre tendencia)
- Marzo: +4,798 unidades (+11.8% sobre tendencia)


Por el contrario, los meses de menor demanda son:

- Noviembre: -5,427 unidades (-13.4% bajo tendencia)
- Septiembre: -4,816 unidades (-11.9% bajo tendencia)
- Febrero: -4,287 unidades (-10.6% bajo tendencia)

Este patrón estacional es consistente con las temporadas características del sector de licorería en Honduras. Los picos de demanda en marzo-junio coinciden con celebraciones de Semana Santa. Los valles en febrero y septiembre corresponden a períodos post-festividades (después de fin de año) y post-vacaciones escolares respectivamente, mientras que noviembre es tradicionalmente un mes de menor consumo previo a las festividades de diciembre. La identificación clara de esta componente estacional valida la inclusión de features MES_SIN y MES_COS en los modelos predictivos.

4.1.4. VISUALIZACIÓN DE DATOS

Ilustración 7: Histograma de variables cuantitativas



Fuente: Elaboración propia con datos de la empresa


La Ilustración 5 presenta los histogramas de distribución de las cuatro variables cuantitativas principales del conjunto de datos. En el gráfico de **CANTIDAD** se observa una concentración marcada en valores bajos, con la mayoría de las transacciones ubicándose cerca de cero, lo que se confirma con una mediana de 2.00 unidades significativamente inferior a la media de 7.67. Esta asimetría positiva pronunciada indica que, si bien las ventas típicas involucran cantidades reducidas, existen transacciones de volumen considerable que elevan el promedio.

Las distribuciones de **COSTO** y **PRECIO VENTA** exhiben patrones similares, con alta concentración en los rangos inferiores y colas extendidas hacia la derecha. Los valores medianos

(L.20.48 y L.26.00 respectivamente) se posicionan por debajo de las medias (L.36.02 y L.48.15), reflejando la heterogeneidad del catálogo de productos que incluye artículos de consumo masivo de bajo valor junto con productos de mayor precio unitario.

La variable **UTILIDAD** muestra igualmente una distribución asimétrica positiva, con mediana de L.15.17 y media de L.34.87. La forma de esta distribución sugiere que la mayor parte de las transacciones genera márgenes modestos, mientras que un grupo más reducido de operaciones aporta utilidades significativamente superiores, patrón característico de negocios de retail con alto volumen de transacciones.

Ilustración 8: Diagramas de caja para identificación de valores atípicos



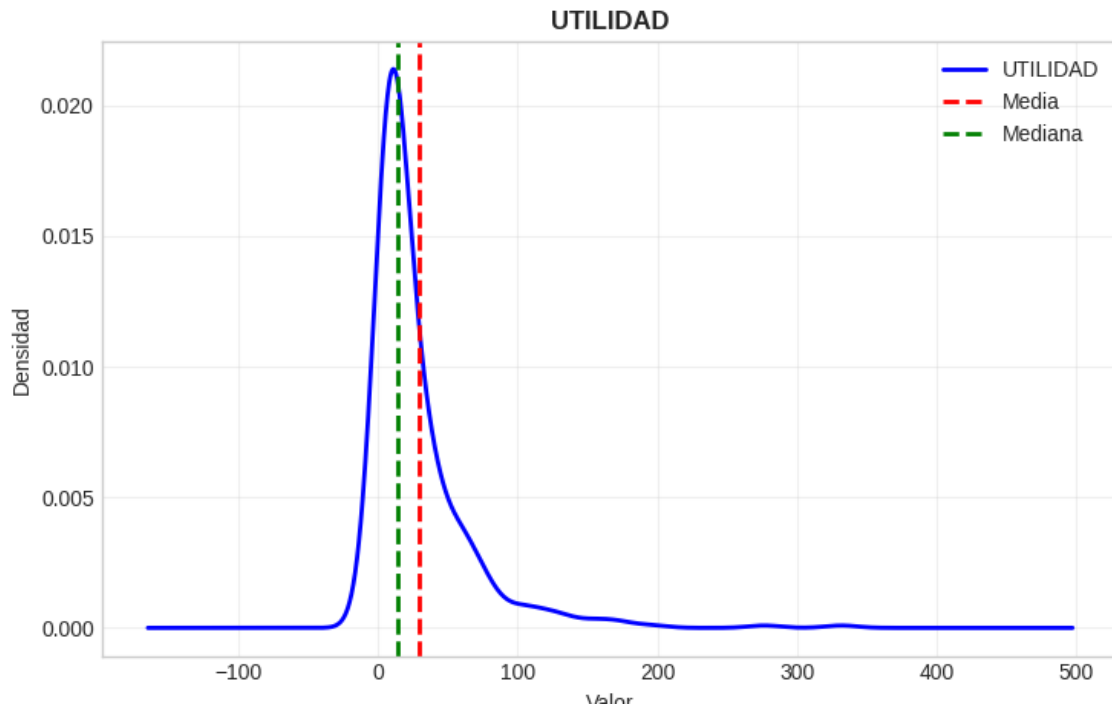
Fuente: Elaboración propia con datos empresariales.

La Ilustración 6 presenta los diagramas de caja que permiten visualizar la dispersión y simetría de las variables cuantitativas, así como identificar valores atípicos. Las cuatro variables exhiben cajas muy comprimidas cerca de sus valores mínimos, con medianas (línea roja) posicionadas en la parte inferior del rango intercuartílico, confirmando las distribuciones asimétricas identificadas previamente.

Los numerosos puntos circulares dispersos por encima de las cajas representan outliers, que

en conjunto abarcan entre 5.94% y 7.75% de las transacciones según la variable. Estos valores corresponden principalmente a operaciones mayoristas, productos premium y transacciones institucionales, siendo comercialmente válidos. En el caso de UTILIDAD, se observan también algunos outliers negativos asociados a liquidaciones o promociones especiales.

Ilustración 9: Estimación de densidad Kernel de las variables cuantitativas



Fuente: Elaboración propia

La Figura 7 muestra las curvas de densidad kernel (KDE) que proporcionan una visualización suavizada de las distribuciones de probabilidad. Las cuatro variables presentan distribuciones unimodales con asimetría positiva pronunciada, caracterizadas por picos agudos cerca de valores bajos y colas extendidas hacia la derecha.

La CANTIDAD exhibe el pico más pronunciado, indicando alta concentración en valores cercanos a cero, seguido de una cola larga que representa transacciones de mayor volumen. COSTO y PRECIO VENTA muestran patrones similares entre sí, consecuencia de la política de pricing proporcional. La distribución de UTILIDAD presenta un pico en valores positivos bajos con cola hacia valores superiores, y una pequeña masa de probabilidad en el rango negativo correspondiente a transacciones con pérdida (liquidaciones o promociones).

La separación entre media (línea roja) y mediana (línea verde) es evidente en todas las variables, confirmando cuantitativamente la asimetría observada visualmente en las curvas.

Tabla 19: Distribución de transacciones por estrato

Estratos	Frecuencia	Porcentaje
Cerveza Internacional	28150	25.38
Cerveza Nacional	23703	21.37
Tabaco	21527	19.41
Snack	14237	12.82
Licor	13175	11.88
Otros	10124	9.13

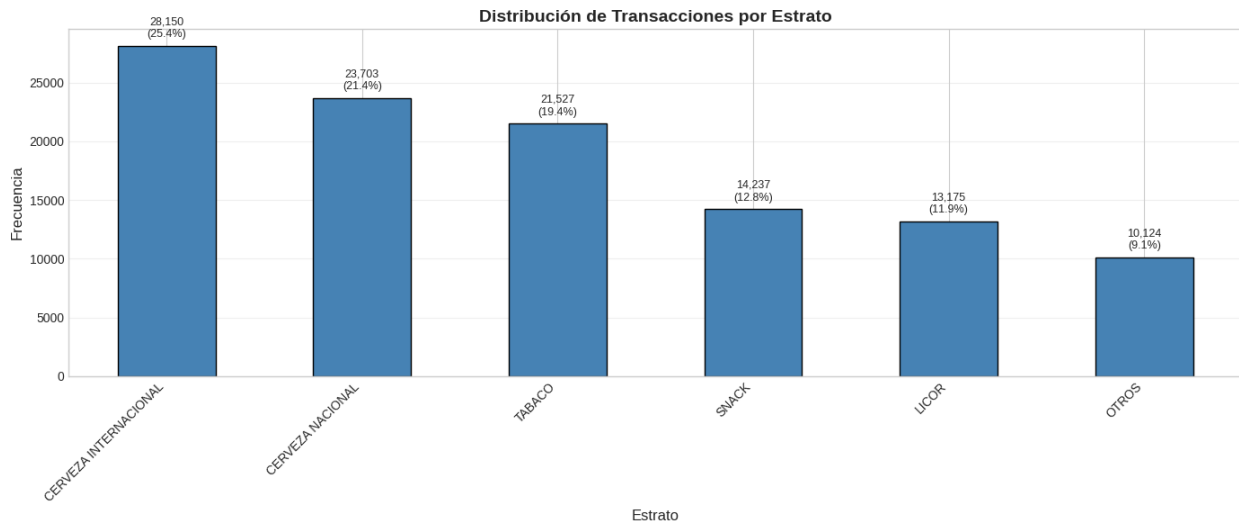
Fuente: Elaboración propia.

La Tabla 19 presenta la distribución de las transacciones analizadas según los seis estratos definidos en el diseño muestral. Se observa una concentración significativa en las categorías de cerveza, que en conjunto representan el **46.75%** del total de operaciones. Específicamente, Cerveza Internacional lidera con 28,150 transacciones (25.38%), seguida por Cerveza Nacional con 23,703 transacciones (21.37%).

El estrato Tabaco ocupa el tercer lugar con 21,527 transacciones (19.41%), conformando junto con las categorías de cerveza aproximadamente dos tercios del volumen total de operaciones. Los estratos secundarios incluyen Snack (12.82%), Licor (11.88%) y Otros (9.13%), que, si bien representan proporciones menores, mantienen volúmenes comercialmente relevantes.

Esta distribución confirma la aplicación del principio de Pareto en el negocio, donde un número reducido de categorías concentra la mayor parte de la actividad transaccional. La heterogeneidad observada justifica la implementación de políticas diferenciadas de gestión de inventarios según el estrato, priorizando disponibilidad y reabastecimiento continuo en las tres categorías principales.

Ilustración 10: Distribución de frecuencias por estrato



Fuente: Elaboración propia

La Ilustración 8 representa gráficamente la distribución de transacciones por estrato presentada en la Tabla 15. El gráfico de barras permite visualizar de manera inmediata la dominancia de tres estratos principales: Cerveza Internacional (28,150 transacciones, 25.38%), Cerveza Nacional (23,703 transacciones, 21.37%) y Tabaco (21,527 transacciones, 19.41%).

La altura decreciente de las barras evidencia la estructura jerárquica del portafolio, con una clara diferenciación entre estratos de alta rotación y estratos secundarios. Los tres estratos principales mantienen frecuencias superiores a 23,000 transacciones, mientras que los estratos secundarios (Snack, Licor y Otros) presentan volúmenes entre 11,000 y 17,000 transacciones.

Ilustración 11: Proporción relativa de transacciones por estrato



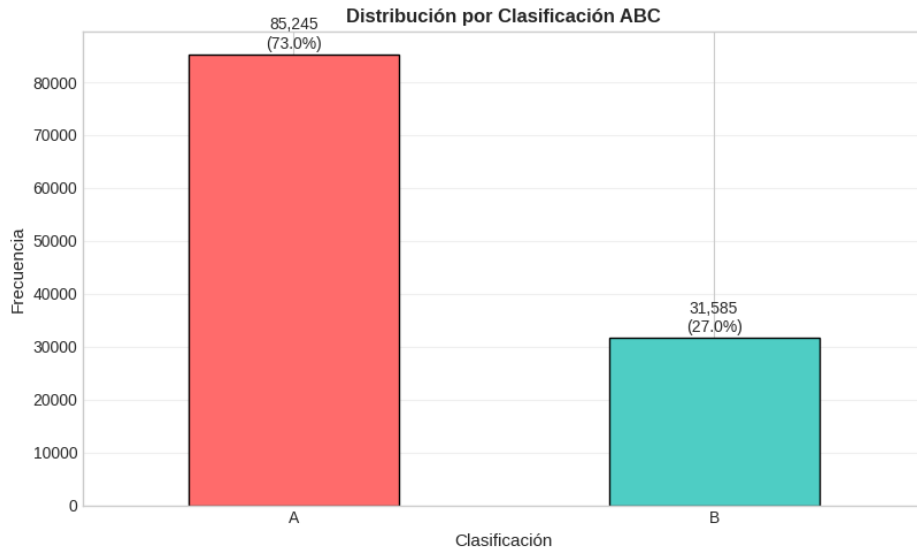
Fuente: Elaboración propia.

La Figura 9 presenta un gráfico circular que complementa la visualización anterior al enfatizar las proporciones relativas de cada estrato respecto al total. Esta representación facilita la comprensión de la estructura porcentual del negocio, donde aproximadamente una cuarta parte de las transacciones (25.4%) corresponde a Cerveza Internacional, representada por el segmento de mayor tamaño.

El gráfico evidencia que los tres segmentos más grandes (colores rosa, mostaza y verde) ocupan conjuntamente cerca de dos tercios del círculo, confirmando visualmente la concentración del negocio en las categorías de cerveza y tabaco. Los segmentos de Snack (12.8%), Licor (11.9%) y Otros (9.1%) completan el portafolio con proporciones significativas pero menores.

Ambas visualizaciones confirman el patrón de concentración identificado en la Tabla 15, donde un número reducido de estratos genera la mayor parte de la actividad transaccional. Esta característica distribucional, consistente con el principio de Pareto (80-20), fundamenta la implementación de un sistema de gestión diferenciado que priorice recursos y atención según la importancia estratégica de cada categoría.

Ilustración 12: Distribución de transacciones por clasificación ABC




Fuente: Elaboración propia

La distribución observada en la Figura 10 valida la estrategia de segmentación del portafolio adoptada por la empresa. La predominancia de productos clase A (76.8%) indica que la operación se concentra en artículos de mayor contribución a la rentabilidad, característica deseable en negocios orientados a maximizar eficiencia operativa. Los productos clase B, aunque representan una proporción menor (23.2%), mantienen un volumen significativo que justifica su inclusión en estrategias de gestión.

Esta estructura de portafolio tiene implicaciones directas para las políticas de inventario. Los productos clase A requieren disponibilidad garantizada mediante niveles de stock de seguridad calculados para minimizar quiebres, dado su impacto directo en los ingresos y la satisfacción del cliente. Los productos clase B pueden gestionarse con políticas ligeramente más flexibles, balanceando disponibilidad con costos de mantenimiento de inventario.

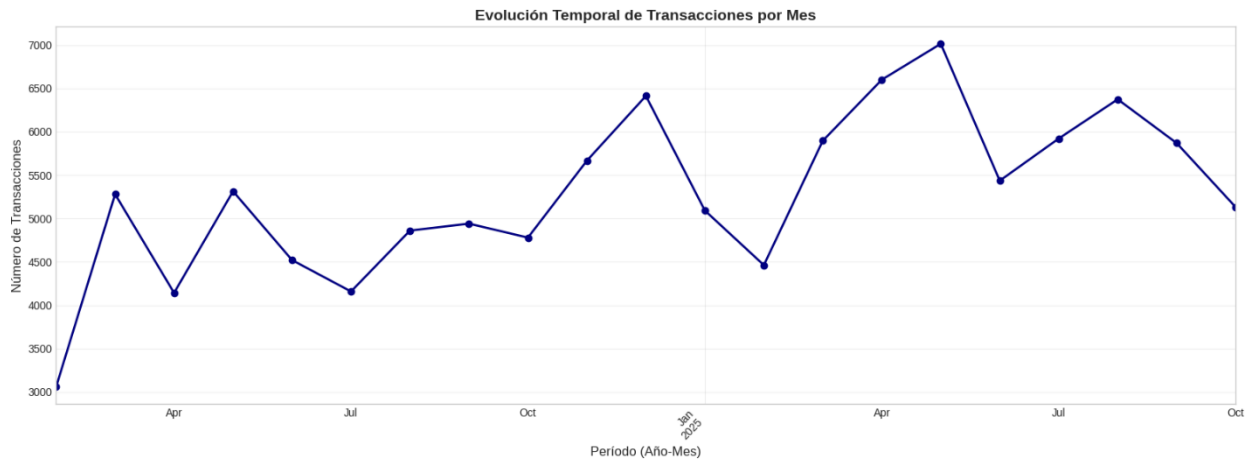
Ilustración 13: Top 20 productos más vendidos



Fuente: Elaboración propia.

El análisis muestra una marcada concentración en unos pocos productos líderes. COORS LIGHT lata 12 oz encabeza la lista con la mayor frecuencia de ventas, seguido por IMPERIAL lata 12 oz y MICHELOB ULTRA lata, que también destacan por su alta rotación. En general, las bebidas principalmente cervezas y refrescos dominan el ranking, lo cual evidencia una fuerte preferencia del consumidor por este tipo de productos. Asimismo, algunos artículos de tabaco aparecen dentro de los primeros puestos, aunque con volúmenes notablemente menores en comparación con las bebidas. En conjunto, la gráfica refleja una estructura de ventas donde pocos productos concentran la mayor demanda, revelando patrones claros de consumo dentro del portafolio analizado.

Ilustración 14: Evolución temporal de transacciones mensuales



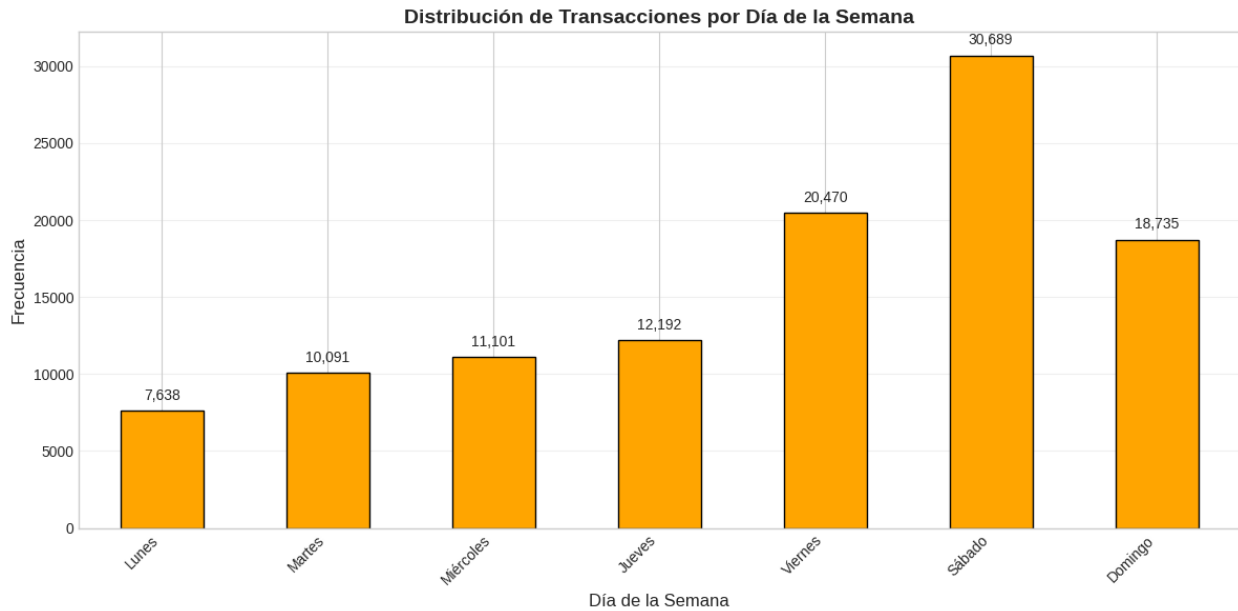
Fuente: Elaboración propia.

La Figura 13 presenta la serie temporal del número de transacciones mensuales durante el período analizado (febrero 2024 a octubre 2025). El gráfico permite identificar patrones de estacionalidad, tendencias y variaciones en el volumen de actividad comercial a lo largo del tiempo.

Se observa un comportamiento fluctuante con varios picos y valles marcados. El período inicial (febrero 2024) muestra un volumen relativamente bajo, cercano a las 3,000 transacciones. La serie experimenta un crecimiento progresivo con oscilaciones, alcanzando un primer pico importante en noviembre 2024 con aproximadamente 6,700 transacciones. Posteriormente, se identifica una caída significativa en diciembre 2024, descendiendo a cerca de 4,900 transacciones, posiblemente asociada a efectos estacionales de fin de año.

El punto más alto de la serie se registra en abril 2025, con más de 7,300 transacciones, seguido de una disminución abrupta en mayo 2025. Esta variabilidad sugiere la existencia de factores estacionales o promocionales que influyen en el comportamiento de compra. Durante el segundo semestre de 2025, la serie muestra una tendencia ligeramente descendente con fluctuaciones moderadas.

Ilustración 15: Distribución de transacciones por día de la semana




Fuente: Elaboración propia.

La Figura 14 presenta la distribución del volumen de transacciones según el día de la semana, proporcionando información sobre los patrones de consumo semanales. Este análisis resulta fundamental para la planificación operativa.

El gráfico revela un patrón marcadamente diferenciado a lo largo de la semana. El sábado se destaca como el día de mayor actividad con 30,689 transacciones (28% del total semanal), seguido por el viernes con 20,470 transacciones (18%) y el domingo con 18,735 transacciones (17%). Estos tres días concentran conjuntamente el 63% de la actividad semanal, evidenciando una clara preferencia por las compras durante el fin de semana.

Los días laborables presentan volúmenes considerablemente menores y más uniformes entre sí. El lunes registra el volumen más bajo con 7,638 transacciones (7%), mostrando un crecimiento gradual hasta el fin de semana.

Ilustración 16: Comparación de utilidad por estrato



Fuente: Elaboración propia.

En primer lugar, se observa que Cerveza Internacional es el estrato con mayor aporte total de utilidad (L. 1,661,354.07), además de presentar el promedio más alto (L. 59.02 por transacción). Este estrato también muestra la mayor dispersión, con una desviación estándar considerable (L. 115.56) y un rango amplio entre los valores mínimo y máximo. Esto indica que, aunque en promedio genera utilidades positivas, existen transacciones con pérdidas y otras con utilidades excepcionalmente altas, lo cual sugiere un comportamiento altamente variable dentro del estrato.


El estrato de Cerveza Nacional presenta un aporte total y promedio menores que los de cerveza internacional, aunque con una tendencia similar: utilidades generalmente positivas acompañadas de una dispersión moderada. El estrato de Licor también destaca por su elevado aporte total (L. 770,927.53) y por un promedio de utilidad relativamente alto (L. 58.51), pero al igual que las cervezas, presenta valores extremos negativos y positivos, indicando variabilidad y presencia de outliers.

Por otro lado, los estratos de Tabaco, Snacks y Otros muestran utilidades promedio más bajas, evidenciando menor rentabilidad por transacción. No obstante, estos estratos exhiben menor dispersión, lo cual sugiere un comportamiento más estable y predecible, aunque con menos potencial

de utilidad por unidad vendida.

La Ilustración 14 de caja complementa estos hallazgos, mostrando visualmente la concentración de datos alrededor de valores bajos de utilidad. En todos los estratos se identifican múltiples outliers, lo que confirma la existencia de transacciones atípicas, tanto con pérdidas como con utilidades muy elevadas. Estos valores atípicos son especialmente frecuentes en los estratos de Cerveza Internacional, Cerveza Nacional y Licor, fortaleciendo la conclusión de que estos grupos poseen mayor volatilidad en su utilidad.

Ilustración 17: Matriz de correlación de Pearson entre variables cuantitativas




Fuente: Elaboración propia.

La matriz de correlación presentada en la Figura 15 proporciona insights valiosos sobre las relaciones estructurales entre las variables del negocio. La correlación casi perfecta entre COSTO y PRECIO VENTA ($r = 0.991$) constituye el hallazgo más relevante desde la perspectiva de estrategia comercial, sugiriendo que la empresa opera con un esquema de markup relativamente constante.

Si bien esta política de pricing tiene ventajas en términos de simplicidad operativa, también presenta limitaciones estratégicas. Un enfoque basado exclusivamente en costos no considera factores como elasticidad precio-demanda o valor percibido por el cliente. Para el sistema de inteligencia de negocios propuesto, este hallazgo sugiere una oportunidad de optimización mediante estrategias de pricing dinámico.

La correlación positiva entre CANTIDAD y UTILIDAD ($r = 0.602$), aunque significativa, no alcanza niveles que sugieran proporcionalidad directa. Esta característica indica que el incremento de volumen no siempre se traduce en aumentos proporcionales de rentabilidad, posiblemente debido a variaciones en márgenes unitarios o descuentos por volumen.

Ilustración 18: Matriz de diagrama de dispersión



Fuente: Elaboración propia.

La Ilustración 16 muestra una **matriz de diagramas de dispersión** que permite observar las relaciones existentes entre las variables *Cantidad* y *Utilidad*. La variable *Cantidad* presenta una alta concentración de valores cercanos a cero, lo que sugiere que la mayoría de los productos se venden en volúmenes bajos, mientras que solo unos pocos alcanzan cantidades significativamente mayores. Por su parte, la *Utilidad* muestra una distribución muy concentrada alrededor de valores bajos, con algunos casos atípicos que reflejan utilidades elevadas.

En conjunto, los diagramas revelan relaciones principalmente no lineales y una notable dispersión entre las variables, lo que evidencia la heterogeneidad de los datos y la posible necesidad de aplicar transformaciones o normalizaciones antes de proceder con el modelado predictivo.

Tabla 20: Resumen de outliers

Variable	Q1	Q3	IQR	Límite Inferior	Límite Superior	N° Outliers	% Outliers
CANTIDAD	1.00	6.00	5.00	-6.50	13.50	15096	13.61
COSTO	14.58	27.80	13.21	-5.24	47.62	11729	10.57
PRECIO	22.00	35.00	13.00	2.50	54.50	17813	16.06
VENTA							
UTILIDAD	7.92	41.34	33.42	-42.21	91.47	8142	7.34

Fuente: Elaboración propia

Interpretación:

- Cantidad: El rango de valores de la variable Cantidad varía entre 1.00 y 6.00, pero fuera de este rango se detectan varios valores extremos (outliers) que superan el límite superior de 13.50, alcanzando valores tan altos como 4800. Estos outliers representan un 13.61% de los datos.
- Costo: El rango de valores de la variable Costo se encuentra entre 14.58 y 27.80, y los valores fuera de este rango que superan los 47.69 y hasta los 1211.40 se consideran outliers. El 10.57% de los datos son valores extremos.
- Precio de venta: En el Precio de Venta, los valores normales deben estar entre 2.50 y 54.50. Sin embargo, hay una cantidad significativa de valores extremos (outliers) que superan este rango, con valores tan bajos como 1.42 y hasta 1500. Esto representa un 16.06% de los datos.

- Utilidad: La Utilidad tiene un rango intercuartílico amplio entre 7.92 y 41.34, pero también presenta valores atípicos significativos. El límite inferior está en -42.21, mientras que el límite superior es 91.47. Los outliers en esta variable alcanzan valores tan bajos como -1669.99 y tan altos como 8435.52, representando un 7.34% de los datos.

4.1.5. CONCLUSIONES DEL EDA

El análisis exploratorio realizado sobre el conjunto de 116,830 transacciones comerciales correspondientes al período febrero 2024 a octubre 2025 ha permitido identificar características fundamentales de los datos que orientarán el desarrollo del sistema de inteligencia de negocios propuesto. A continuación, se presentan los hallazgos más relevantes organizados por áreas temáticas.

4.1.4.1 CARACTERIZACIÓN GENERAL DEL CONJUNTO DE DATOS

El conjunto de datos analizado abarca 632 días de operación comercial, con registro de 177 productos únicos (SKUs) distribuidos en 6 estratos principales. Esta amplitud temporal y diversidad de productos proporciona una base sólida para el análisis, permitiendo capturar tanto patrones regulares como variaciones estacionales en el comportamiento de ventas.

La ausencia de valores faltantes y la inexistencia de registros duplicados confirman la calidad del proceso de captura de información en la empresa. Este hallazgo resulta particularmente relevante, ya que garantiza la confiabilidad de los análisis posteriores y elimina la necesidad de imputaciones que pudieran introducir sesgos en los resultados.

4.1.4.2 COMPORTAMIENTO DE LAS VARIABLES CUANTITATIVAS

El análisis de las variables cuantitativas revela patrones diferenciados que merecen atención especial. La cantidad promedio por transacción se sitúa en 7.50 unidades, aunque la mediana de 2.00 unidades indica que la mayoría de las ventas involucran volúmenes relativamente pequeños. Esta discrepancia entre media y mediana, junto con un coeficiente de variación de 429.29%, evidencia la presencia de transacciones atípicas de gran volumen que, lejos de constituir errores, representan ventas mayoristas o compras institucionales que son parte natural del negocio.

En cuanto a los aspectos económicos, el costo promedio de L.34.23 y el precio de venta promedio de L.45.80 reflejan márgenes de comercialización variables según el tipo de producto. La alta variabilidad observada en estas variables (coeficientes de variación superiores al 210%) responde

a la heterogeneidad intrínseca del catálogo, que incluye productos de consumo masivo de bajo valor unitario junto con artículos de mayor precio.

La utilidad acumulada de L.3,879,595.61 durante el período analizado, con un promedio de L.33.21 por transacción, sugiere un modelo de negocio basado en alto volumen de transacciones más que en márgenes individuales elevados. La mediana de L.13.65 indica que aproximadamente la mitad de las transacciones genera utilidades modestas, mientras que un grupo más reducido de operaciones aporta márgenes significativamente superiores.

4.1.4.3 DISTRIBUCIÓN POR ESTRATOS Y CONCENTRACIÓN DEL NEGOCIO

La distribución de transacciones por estratos revela una concentración marcada en las categorías de cerveza. Específicamente, Cerveza Internacional y Cerveza Nacional representan conjuntamente el 44.39% del total de transacciones (24.10% y 20.29% respectivamente), seguidas por Tabaco con 19.81%. Este patrón de concentración tiene implicaciones directas para las políticas de inventario, ya que sugiere la necesidad de mantener disponibilidad constante en estos tres estratos que, en conjunto, representan casi dos tercios de la actividad comercial.

Los estratos de Snack (14.56%), Licor (11.28%) y Otros (9.96%) complementan el portafolio con volúmenes significativos pero menores, requiriendo estrategias diferenciadas de gestión que equilibren disponibilidad con rotación de inventario.

La clasificación ABC de los productos confirma el enfoque estratégico de la empresa en artículos de alta y media rentabilidad. La distribución observada valida la aplicación del principio de Pareto en la gestión del portafolio, donde una proporción relativamente pequeña de productos genera la mayor parte del valor económico.

4.1.4.4 RELACIONES ENTRE VARIABLES Y PATRONES IDENTIFICADOS

El análisis de correlaciones ha identificado dos relaciones significativas que resultan coherentes con la lógica del negocio. La correlación positiva fuerte entre Cantidad y Utilidad ($r = 0.601$) confirma que el volumen de venta es un determinante importante de la rentabilidad por transacción, sugiriendo que estrategias orientadas a incrementar el ticket promedio podrían impactar favorablemente los márgenes.

La correlación casi perfecta entre Costo y Precio de Venta ($r = 0.991$) indica una política de pricing relativamente estandarizada, donde los precios se establecen como múltiplos consistentes del

costo de adquisición. Esta consistencia facilita la proyección de márgenes, aunque también sugiere áreas de oportunidad para implementar estrategias de pricing más dinámicas y diferenciadas por segmento de cliente o período.

4.1.4.5 VALORES ATÍPICOS Y SU INTERPRETACIÓN

La detección de valores atípicos en todas las variables cuantitativas requiere una interpretación cuidadosa. En el caso de Cantidad, se identificaron 6,945 outliers (5.94% del total), que corresponden principalmente a compras institucionales o reposiciones mayoristas. Estos valores, aunque estadísticamente atípicos, representan transacciones comerciales válidas y relevantes para el negocio.

Los outliers en Costo (7,137 casos, 6.11%) y Precio de Venta (7,082 casos, 6.06%) reflejan la diversidad del catálogo, que incluye desde productos de conveniencia de bajo costo hasta artículos premium de mayor valor. La Utilidad presenta 9,060 outliers (7.75%), asociados tanto a transacciones de alto volumen como a productos con márgenes excepcionales.

4.1.4.6 VALIDACIÓN DEL DISEÑO MUESTRAL

El análisis confirma que el diseño de muestreo estratificado proporcional adoptado fue apropiado. Las proporciones observadas en la muestra reflejan adecuadamente la distribución poblacional por estratos, y los estadísticos descriptivos calculados presentan coherencia con el comportamiento esperado del negocio. Esta validación es fundamental, ya que garantiza que los modelos y recomendaciones que se deriven en fases posteriores del proyecto serán representativos de la realidad operativa de la empresa.

4.1.4.7 LIMITACIONES Y CONSIDERACIONES METODOLÓGICAS

Es necesario reconocer algunas limitaciones inherentes al análisis realizado. En primer lugar, el período analizado de 21 meses, aunque sustancial, podría no capturar completamente ciclos económicos de más largo plazo o cambios estructurales en los patrones de consumo. En segundo lugar, el análisis se centra en productos de clasificación A y B, excluyendo deliberadamente productos de menor rentabilidad que, aunque marginales en términos económicos, podrían tener relevancia estratégica para mantener la completitud del portafolio.

Adicionalmente, si bien se han identificado correlaciones significativas entre variables, el análisis exploratorio no permite establecer relaciones causales. La profundización en estas relaciones

requerirá el desarrollo de modelos explicativos más sofisticados en las fases subsecuentes del proyecto.

4.1.4.8 CONCLUSIÓN GENERAL

El análisis exploratorio ha cumplido satisfactoriamente sus objetivos, proporcionando una caracterización comprehensiva del conjunto de datos y estableciendo las bases para el desarrollo del sistema de inteligencia de negocios. Los patrones identificados confirman la viabilidad técnica del proyecto y han permitido identificar áreas específicas donde la implementación de herramientas analíticas avanzadas puede generar valor tangible para la organización.

La calidad de los datos, la diversidad del portafolio y la existencia de patrones claramente diferenciados entre estratos constituyen activos valiosos que facilitarán el desarrollo de soluciones analíticas efectivas. Los hallazgos documentados servirán como referencia para el diseño de algoritmos de optimización, el establecimiento de métricas de desempeño y la definición de reglas de negocio en el sistema de inteligencia de negocios.

El siguiente paso natural en la progresión metodológica consiste en el desarrollo de modelos predictivos que, fundamentados en los insights obtenidos en esta fase exploratoria, permitan anticipar comportamientos futuros de demanda y optimizar las decisiones operativas relacionadas con la gestión de inventarios.

4.2 INFORME DEL PROCESO DE RECOLECCIÓN DE DATOS

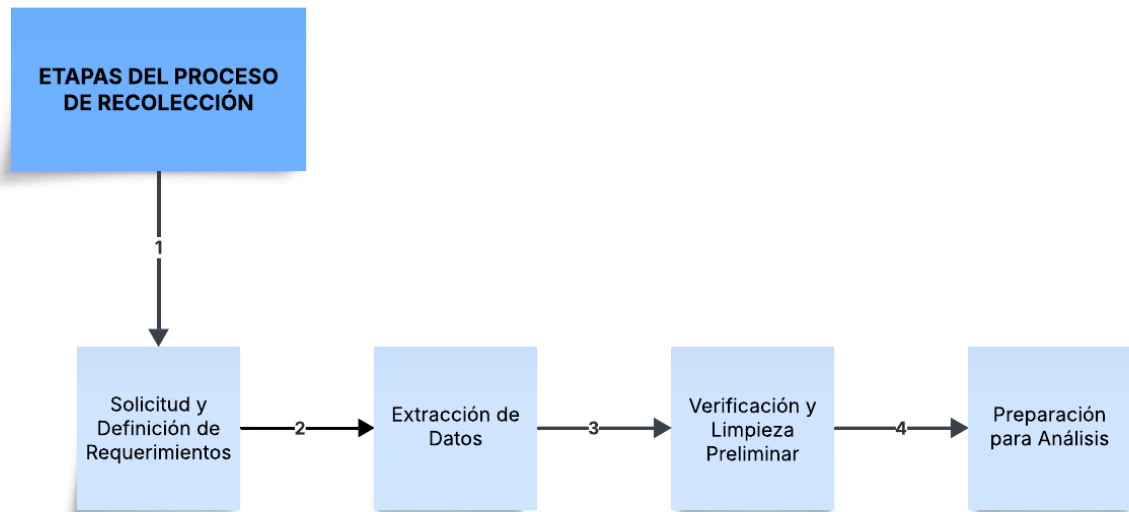
4.2.1 DESCRIPCIÓN DEL PROCESO

La recolección de datos para este estudio se realizó mediante extracción directa del sistema de gestión de ventas implementado por Licorería Josway en el año 2023. El sistema, desarrollado sobre la base de datos MariaDB, registra de forma transaccional todas las operaciones comerciales de la empresa, incluyendo información detallada sobre productos, precios, cantidades y fechas de cada transacción.

4.2.1.1 ETAPAS DEL PROCESO DE RECOLECCIÓN

El proceso de recolección de datos se estructuró en cuatro etapas secuenciales claramente diferenciadas:

Ilustración 19: Etapas del proceso de recolección de datos



Fuente: Elaboración propia

Etapa 1: Solicitud y Definición de Requerimientos

Se estableció contacto con los propietarios del negocio para solicitar acceso a la información histórica de ventas. En esta etapa se definieron los requerimientos específicos de datos necesarios para el análisis, incluyendo el período temporal de interés (febrero 2024 - octubre 2025) y las variables requeridas (fecha, número de factura, producto, código, cantidad, costo, precio de venta, utilidad, categorización y métricas de rotación).

Etapa 2: Extracción de Datos

La extracción se realizó mediante la funcionalidad de reportería integrada en el sistema de gestión. El investigador accedió personalmente a la interfaz del sistema y ejecutó las consultas predefinidas para generar reportes de ventas del período especificado. Los datos se exportaron directamente desde el módulo de reportería en formato Excel (.xlsx), aprovechando las capacidades

nativas del sistema para la generación de archivos estructurados.

Etapa 3: Verificación y Limpieza Preliminar

Una vez obtenidos los archivos de datos, se procedió a una revisión inicial de la estructura y completitud de la información. Durante esta etapa se identificaron y corrigieron aspectos de formato del archivo Excel, específicamente relacionados con celdas combinadas que impedían el procesamiento automático de los datos. Esta limpieza estructural garantizó la compatibilidad de los datos con las herramientas de análisis estadístico.

Se realizaron consultas informales con los propietarios del negocio para comprender aspectos específicos del sistema de registro y la lógica de categorización de productos. Estas consultas permitieron aclarar la estructura de datos y validar la interpretación correcta de las variables disponibles.

Etapa 4: Preparación para Análisis

Los datos limpiados estructuralmente se procesaron mediante una combinación de herramientas. Microsoft Excel se utilizó para análisis exploratorios preliminares y la generación de tablas dinámicas que facilitaron la comprensión inicial de la distribución de datos. Posteriormente, el conjunto de datos se procesó mediante Python, lenguaje de programación especializado en análisis de datos, para la realización del análisis exploratorio formal, la generación de visualizaciones y la aplicación de técnicas estadísticas avanzadas.

4.2.1.2 RECURSOS UTILIZADOS

Los recursos empleados en el proceso de recolección y análisis de datos fueron tanto tecnológicos como humanos. En cuanto a los **recursos tecnológicos**, se utilizó el sistema de gestión de ventas de la Licorería Josway, basado en MariaDB, como fuente principal de información. Además, se empleó Microsoft Excel 2019 para realizar la limpieza estructural de los datos y un análisis preliminar. Para el análisis estadístico más profundo, se usó Python 3.8 junto con librerías especializadas como *pandas*, *numpy*, *matplotlib* y *seaborn*. Todo el procesamiento se llevó a cabo en una computadora personal equipada con un procesador Intel Core i5, 8 GB de memoria RAM y el sistema operativo Windows 10.

En cuanto a los **recursos humanos**, el proceso estuvo a cargo de un investigador principal, responsable de la ejecución de todas las etapas del estudio, y contó con la colaboración de los

propietarios del negocio, quienes proporcionaron acceso al sistema de gestión y ofrecieron aclaraciones sobre el proceso de registro de las ventas.

4.2.1.3 TEMPORALIDAD DEL PROCESO

El proceso completo de recolección de datos tuvo una duración inferior a un día laboral. La rapidez del proceso se atribuyó a varios factores favorables: la disponibilidad inmediata del sistema de gestión, la claridad en la definición de requerimientos, la funcionalidad integrada de reportería que permitió exportaciones directas sin necesidad de consultas SQL personalizadas, y la disposición colaborativa de los propietarios del negocio para facilitar el acceso necesario.

Esta eficiencia temporal contrasta favorablemente con procesos de recolección de datos más complejos que podrían requerir desarrollo de consultas especializadas, negociaciones extensas de permisos, o múltiples iteraciones de solicitud-revisión-corrección. La agilidad del proceso permitió dedicar mayor tiempo y recursos a las etapas posteriores de limpieza, análisis e interpretación de datos.

4.2.2 PARTICIPANTES O FUENTES DE INFORMACIÓN

4.2.2.1 CARACTERÍSTICAS DE LA POBLACIÓN ESTUDIADA

La población bajo estudio comprende el universo de transacciones comerciales registradas en el sistema de gestión de Licorería Josway durante el período comprendido entre febrero de 2024 y octubre de 2025. Específicamente, tras la aplicación de criterios de inclusión y exclusión metodológicamente fundamentados, la población elegible se constituyó de 116,830 transacciones que cumplieron los requisitos establecidos para el análisis.

Los **criterios de inclusión** utilizados para delimitar la población del estudio se establecieron de la siguiente manera:

Se consideraron únicamente los productos clasificados como A o B según la metodología de análisis ABC, correspondientes a artículos de alta y media rentabilidad, respectivamente. Asimismo, se incluyeron los productos con rotación activa durante el período de estudio, es decir, aquellos que registraron al menos una venta dentro del intervalo analizado. También se tomaron en cuenta únicamente las transacciones con información completa en todas las variables de interés (fecha, producto, cantidad, precio, costo y utilidad), y que se encontraran dentro del marco temporal establecido, comprendido entre febrero de 2024 y octubre de 2025.

En cuanto a los **criterios de exclusión**, se dejaron fuera del análisis los productos clasificados como C, correspondientes a artículos de baja rentabilidad o con una contribución marginal reducida. Igualmente, se excluyeron los productos discontinuados o sin movimiento durante el período de estudio, así como las transacciones con datos incompletos o inconsistentes que no pudieron ser validadas. Finalmente, se descartaron las operaciones no comerciales, tales como ajustes de inventario, devoluciones sin reemplazo y correcciones contables.

Esta delimitación respondió al objetivo central del estudio: optimizar la gestión de inventarios de productos que impulsan el desempeño económico del negocio. La exclusión de productos clase C, si bien reduce la cobertura poblacional, permite enfocar recursos analíticos en artículos estratégicamente relevantes.

4.2.2.2 CARACTERÍSTICAS DE LA MUESTRA SELECCIONADA

En esta investigación se utilizó la población de 136,479 transacciones, luego de los filtros de valores atípicos y criterios de inclusión y exclusión quedaron 110,897 transacciones para analizar.

4.2.3 INSTRUMENTOS UTILIZADOS

4.2.3.1 NATURALEZA DE LOS INSTRUMENTOS

A diferencia de estudios que emplean instrumentos de recolección primaria (cuestionarios, entrevistas estructuradas, observación sistemática), este estudio se fundamentó en datos transaccionales generados automáticamente por el sistema de gestión empresarial. Por tanto, el "instrumento" principal de recolección fue el propio sistema de información, específicamente su módulo de reportería.

Esta aproximación metodológica presenta ventajas significativas en términos de objetividad, ya que los datos no están sujetos a sesgos de reporte, memoria o interpretación que podrían afectar instrumentos basados en percepción o recuerdo. Los registros transaccionales capturan información en el momento exacto de ocurrencia del evento comercial, garantizando precisión temporal y factual.

4.2.3.2 SISTEMA DE GESTIÓN COMO INSTRUMENTO DE CAPTURA

El sistema de gestión de la Licorería Josway, implementado en 2023 sobre una arquitectura basada en MariaDB, opera como un sistema de punto de venta (POS) integrado con módulos de gestión de inventarios.

Entre sus características más relevantes para la recolección de datos se encuentra el registro automático de cada transacción con un timestamp preciso, lo que garantiza la trazabilidad temporal de las operaciones. Además, permite la captura de información de productos mediante el uso de códigos de barra o la búsqueda directa en el catálogo digital.

El sistema realiza el cálculo automático de la utilidad, considerando los costos actualizados y los precios de venta vigentes, y organiza toda la información en una base de datos relacional estructurada. También cuenta con un módulo de reportería que ofrece opciones de filtrado por fecha, producto y categoría, así como con una funcionalidad de exportación a formatos estándar como Excel y CSV, lo que facilita el análisis y la integración con otras herramientas.

Si bien no se llevó a cabo una validación formal del sistema de información, dado que este no fue diseñado con fines de investigación, se realizó una verificación de su confiabilidad mediante diversos procedimientos. En primer lugar, se efectuó una comprobación de consistencia interna, verificando que la utilidad registrada cumpliera con la fórmula **Utilidad = (Precio - Costo) × Cantidad**.

Posteriormente, se llevó a cabo una validación de rangos, confirmando que los valores numéricos se encontraran dentro de límites razonables y coherentes con la operación del negocio. También se realizó una verificación de completitud para asegurar la ausencia de valores faltantes en las variables consideradas críticas para el análisis. Finalmente, se efectuó una consulta con los usuarios del sistema, específicamente con los propietarios del negocio, quienes confirmaron que el sistema registra las transacciones de manera fiel y representativa de las operaciones.

La ausencia de valores faltantes en el conjunto de datos extraído (116,830 registros completos) constituye evidencia indirecta de la robustez del sistema y los controles de calidad implementados en su operación rutinaria.

4.2.3.3 HERRAMIENTAS DE PROCESAMIENTO Y ANÁLISIS

Microsoft Excel se utilizó como herramienta inicial de apoyo para el análisis de los datos, permitiendo realizar una inspección visual de la estructura del conjunto de datos, así como la corrección de formatos, incluyendo la descombinación de celdas y la estandarización de los tipos de datos. Adicionalmente, se empleó para la generación de tablas dinámicas, las cuales facilitaron un análisis exploratorio preliminar, y para la validación de rangos, contribuyendo a la detección de

inconsistencias evidentes antes de proceder con etapas más avanzadas del análisis.

El análisis estadístico formal se llevó a cabo utilizando **Python 3.8** junto con un conjunto de librerías científicas especializadas, ampliamente validadas dentro de la comunidad académica y profesional. En particular, se empleó pandas (v2.0) para la manipulación, estructuración de datos y el cálculo de estadísticos descriptivos; numpy (v1.24) para operaciones numéricas y cálculo matricial; matplotlib (v3.7) para la generación de gráficos estadísticos básicos; seaborn (v0.12) para visualizaciones estadísticas avanzadas y gráficos de distribución; scipy (v1.10) para el análisis estadístico inferencial y el cálculo de correlaciones; y scikit-learn (v1.3) para la aplicación de técnicas de normalización y estandarización de los datos. En conjunto, estas herramientas constituyen el estándar de facto para el análisis cuantitativo en investigación científica y aplicada, respaldadas por amplia documentación, validación por pares y un uso extensivo en publicaciones académicas revisadas.

4.2.3.4 CONSULTAS INFORMALES NO ESTRUCTURADAS

Como complemento a la extracción de datos transaccionales, se realizaron consultas informales con los propietarios del negocio. Estas consultas no siguieron un protocolo estructurado de entrevista, sino que adoptaron la forma de conversaciones exploratorias orientadas a:

- Comprender la lógica de categorización de productos empleada por la empresa
- Aclarar el significado preciso de variables registradas en el sistema
- Validar interpretaciones preliminares sobre patrones observados en los datos
- Obtener contexto sobre eventos específicos que pudieran explicar anomalías o picos en las series temporales

Estas consultas no generaron datos que se incorporaran directamente al análisis cuantitativo, sino que proporcionaron contexto interpretativo que enriqueció la comprensión de los hallazgos estadísticos.

4.2.4 DIFICULTADES ENCONTRADAS

4.2.4.1 INCONSISTENCIAS EN LA CATEGORIZACIÓN DE PRODUCTOS

El principal desafío metodológico encontrado durante el proceso de recolección y preparación de datos se relacionó con inconsistencias en la categorización de productos dentro del sistema. Específicamente, se identificaron casos donde productos estaban asignados a categorías que no correspondían a su naturaleza real.

Ejemplo ilustrativo: Productos de la categoría "Ron" aparecían clasificados bajo la categoría genérica "General", diluyendo la especificidad de la clasificación y potencialmente afectando análisis segmentados por tipo de producto.

Para abordar la inconsistencia detectada en la clasificación de los productos, se implementó un **proceso de reclasificación sistemática** orientado a mejorar la calidad y coherencia de la información. En una primera etapa, se realizó la **identificación de casos problemáticos** mediante la revisión de la distribución de productos por categoría y la validación cruzada con los nombres de los productos, lo que permitió detectar ítems que presentaban una clasificación evidentemente incorrecta.

Posteriormente, se procedió al **establecimiento de reglas de reclasificación**, definiendo criterios explícitos basados en palabras clave presentes en los nombres de los productos, tales como “Ron”, “Vodka” o “Whisky”, los cuales fueron contrastados y validados con los catálogos oficiales de productos de la empresa. Con base en estas reglas, se llevó a cabo una **reclasificación asistida**, corrigiendo las categorizaciones erróneas y reasignando los productos a sus categorías correspondientes. Todo este proceso fue debidamente documentado con el fin de asegurar la **trazabilidad y replicabilidad** de la intervención.

Finalmente, las reclasificaciones realizadas fueron **validadas con los propietarios del negocio**, quienes confirmaron la corrección de la nueva estructura categorial. Si bien esta intervención implicó un consumo adicional de tiempo no contemplado inicialmente, permitió **mejorar sustancialmente la calidad del análisis posterior**, al garantizar que las categorías fueran internamente homogéneas y reflejaran de manera fiel la naturaleza de los productos agrupados.

4.2.4.2 PROBLEMAS DE FORMATO EN ARCHIVOS EXCEL

Un obstáculo técnico menor pero significativo se presentó en la estructura del archivo Excel exportado desde el sistema. Específicamente, algunas columnas del archivo contenían celdas

combinadas, formato comúnmente utilizado en reportes visuales para mejorar presentación, pero incompatible con herramientas de análisis estadístico que requieren estructuras rectangulares consistentes.

Manifestación del problema:

Las celdas combinadas impidieron la correcta lectura del archivo mediante pandas (librería de Python), generando errores de parsing y desalineación de datos. Este problema es común cuando sistemas diseñados para consumo humano (reportes visuales) se utilizan como fuente para análisis automático.

Resolución implementada:

El problema fue resuelto mediante un proceso de reformato en Microsoft Excel previo a la importación de los datos a Python. Dicho proceso incluyó la identificación de columnas con celdas combinadas a través de una inspección visual, la separación de estas celdas utilizando la funcionalidad Unmerge Cells y la replicación de los valores en las celdas previamente combinadas con el fin de mantener la consistencia referencial. Finalmente, se verificó que la estructura resultante cumpliera con el formato tabular requerido, donde cada fila representa una observación y cada columna una variable.

Este preprocesamiento manual, aunque laborioso, fue necesario únicamente una vez y permitió garantizar la compatibilidad de los datos con todas las herramientas de análisis utilizadas posteriormente.

4.2.5 CONSIDERACIONES ÉTICAS

4.2.5.1 MARCO ÉTICO DEL ESTUDIO

Si bien este estudio se basa en datos transaccionales empresariales y no involucra experimentación con sujetos humanos, la investigación se condujo adhiriendo a principios éticos fundamentales de integridad académica, respeto por la propiedad de la información, y responsabilidad en el uso de datos empresariales sensibles.

4.2.5.2 AUTORIZACIÓN FORMAL PARA USO DE DATOS

Se obtuvo autorización formal por escrito de los propietarios de Licorería Josway para utilizar los datos de la empresa con fines académicos. Esta autorización, materializada en una carta oficial,

estableció explícitamente:

- Consentimiento para acceso al sistema de gestión y extracción de datos históricos
- Autorización para uso de los datos en el desarrollo de la tesis de grado
- Permiso para publicación de resultados agregados y análisis en el documento de tesis
- Autorización para mencionar el nombre comercial de la empresa (Licorería Josway) en el documento académico

La obtención de esta autorización formal constituye una práctica ética fundamental en investigación aplicada, garantizando que el uso de datos empresariales cuente con el conocimiento y aprobación explícitos de los propietarios legítimos de la información.

4.2.5.3 CONFIDENCIALIDAD Y PROTECCIÓN DE DATOS

Datos No Anonimizados:

En este estudio, los datos no fueron anonimizados mediante técnicas de ofuscación o eliminación de identificadores, decisión que se fundamentó en varias consideraciones. En primer lugar, la naturaleza de los datos analizados corresponde a transacciones comerciales agregadas que no contienen información personal identificable de clientes individuales; las variables incluidas abarcan fechas, productos, cantidades y precios, pero no incluyen nombres de clientes, números de identificación personal, direcciones ni información de contacto.

En segundo lugar, el nivel de agregación del análisis se centra en transacciones y productos, no en individuos específicos, lo que elimina prácticamente cualquier riesgo de identificación personal. Adicionalmente, se contó con la autorización explícita de la empresa para el uso de datos no anonimizados, incluyendo el derecho a mencionar el nombre comercial del negocio en los reportes y análisis. Finalmente, se considera la ausencia de información sensible personal, dado que el sistema de punto de venta registra las transacciones sin capturar datos personales de los compradores, ya que no se requiere identificación del cliente para las compras al por menor.

Protección de Información Comercial Sensible:

Si bien el nombre de la empresa se menciona abiertamente, se ejerció discreción en la presentación de cierta información que podría considerarse comercialmente sensible:

- Los márgenes de utilidad específicos por producto individual no se desagregan en el documento (solo se presentan estadísticos agregados)
- Las estrategias de pricing específicas se describen en términos generales sin revelar fórmulas exactas de cálculo de precios
- Los volúmenes de venta se presentan en términos agregados y relativos, evitando desagregaciones que pudieran ser explotables competitivamente.

4.2.5.4 INTEGRIDAD EN EL MANEJO DE DATOS

El investigador se comprometió a mantener integridad absoluta en el manejo de los datos, específicamente las representadas en la siguiente tabla:

Tabla 21 Principios Éticos Aplicados en el Proceso de Investigación

Principio	Descripción	Implementación en Este Estudio	Resultado
Integridad en Manejo de Datos	Garantizar que los datos se manejen sin alteraciones indebidas	Documentación de todas las transformaciones Trazabilidad completa del procesamiento Replicabilidad garantizada	Datos íntegros y verificables
Preservación de Datos Originales	Mantener valores sustantivos sin modificaciones	Solo correcciones de formato técnico Reclasificaciones validadas con propietarios derivadas con cálculos explícitos	Versiones originales preservadas
Almacenamiento Seguro	Proteger datos contra acceso no autorizado	Almacenamiento local protegido Dispositivo con contraseña Sin uso de nube publica sin cifrado	Datos bajo custodia segura
Autorización y Consentimiento	Obtener permiso formal para uso de datos	Carta de autorización escrita Consentimiento de propietarios Permiso para mencionar nombre comercial	Autorización formal obtenida
Confidencialidad	Proteger información sensible	Sin datos personales de clientes Análisis a nivel agregado Protección de información comercial sensible	Confidencialidad respetada

Principio	Descripción	Implementación en Este Estudio	Resultado
Reciprocidad	Devolver beneficios a la fuente de datos	Informe ejecutivo comprometido Hallazgos y recomendaciones practicas Contribución al desarrollo empresarial	Beneficio mutuo establecido
Objetividad	Evitar conflictos de interés	Sin relación económica con empresa Sin incentivos financieros Colaboración solo académica	Independencia garantizada
Conformidad Institucional	Cumplir normativas académicas	Diseño revisado por asesor Cumplimiento de estándares de grado Verificación de adecuación ética	Protocolo aprobado

Fuente: Elaboración propia.

No Alteración de Datos Originales:

Los datos extraídos del sistema se conservaron en su formato original, sin realizar modificaciones que alteraran valores sustantivos. Las únicas transformaciones aplicadas incluyeron correcciones de formato técnico, como la separación de celdas combinadas; la reclasificación de categorías inconsistentes, validada con los propietarios del negocio; la creación de variables derivadas mediante cálculos explícitos y documentados; y la normalización y estandarización de los datos con fines estadísticos, manteniendo siempre las versiones originales. Todas estas transformaciones fueron documentadas meticulosamente para asegurar la trazabilidad y la replicabilidad del análisis.

Almacenamiento Seguro:

Los datos se almacenaron en dispositivos personales del investigador con medidas de seguridad básicas (protección por contraseña, sin compartir en servicios de nube pública sin cifrado). Al concluir el estudio, los archivos de datos permanecen bajo custodia del investigador, sin distribución a terceros.

Reciprocidad y Beneficio para la Empresa

Como práctica ética de reciprocidad, al finalizar el estudio se proporcionará a Licorería Josway un informe ejecutivo con los hallazgos principales y recomendaciones prácticas derivadas

del análisis. Esta devolución de resultados constituye un beneficio tangible para la empresa que facilitó acceso a sus datos, contribuyendo al desarrollo de capacidades analíticas internas y fundamentando decisiones de gestión basadas en evidencia.

Ausencia de Conflictos de Interés

El investigador no mantiene relación económica, laboral o de dependencia con Licorería Josway más allá de la colaboración específica para este estudio académico. No existen incentivos financieros, participaciones accionarias o cualquier otro tipo de conflicto de interés que pudiera comprometer la objetividad del análisis o la interpretación de resultados.

Conformidad con Normativas Académicas

Este estudio se desarrolló en conformidad con las normativas éticas establecidas por la institución académica para trabajos de investigación a nivel de grado. Si bien no se requirió aprobación de comité de ética (dado que no involucra experimentación humana, intervenciones clínicas o poblaciones vulnerables), el diseño metodológico fue revisado y aprobado por el asesor académico, quien verificó la adecuación ética del protocolo de investigación.

4.3 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS

Esta sección presenta los resultados derivados de la aplicación sistemática de técnicas de inteligencia de negocios y métodos de machine learning al problema de gestión de inventarios de la Licorería Josway. El análisis articula enfoques tradicionales de la gestión de operaciones —como la clasificación ABC y los modelos EOQ con algoritmos avanzados de aprendizaje automático, lo que permite construir una propuesta híbrida que aprovecha las fortalezas de ambas perspectivas.

La organización de esta sección responde a una secuencia metodológica coherente. En primer lugar, se exponen los resultados del análisis descriptivo que facilitan la comprensión del entorno operativo del negocio. Posteriormente, se desarrollan y evalúan distintos modelos predictivos de machine learning orientados al pronóstico de la demanda. Finalmente, estos pronósticos se integran en el cálculo de parámetros óptimos de inventario y en el diseño de políticas diferenciadas para su gestión.

Cada resultado se vincula explícitamente con los objetivos específicos de la investigación, garantizando la coherencia entre las preguntas planteadas, las herramientas analíticas empleadas y los hallazgos obtenidos. Asimismo, la interpretación de los resultados va más allá de la simple

presentación de cifras, incorporándolos al marco teórico de la gestión de inventarios y destacando sus implicaciones prácticas para la toma de decisiones en la Licorería Josway.

4.3.1 RESULTADOS CUANTITATIVOS

4.3.1.1 PRESENTACIÓN DE DATOS

RESULTADOS ABC

El primer objetivo específico de esta investigación consistía en realizar un diagnóstico exhaustivo de la situación actual de gestión de inventarios mediante la aplicación de la metodología de clasificación ABC. Esta técnica, fundamentada en el principio de Pareto, permite identificar los productos que concentran la mayor proporción de la utilidad del negocio, facilitando la priorización de recursos de gestión donde generan mayor impacto económico.

La aplicación de la clasificación ABC al portafolio de 726 productos únicos (SKUs) de Licorería Josway reveló una distribución que confirma empíricamente el principio 80-20. La Tabla 24 presenta los resultados agregados de esta clasificación.

Tabla 22 Resultados de la Clasificación ABC del Portafolio de Productos

Clasificación	Cantidad de Productos	% de Productos	Utilidad Generada (L)	% de Utilidad	Contribución Acumulada	Interpretación Estratégica
Clase A	52	7.16%	L 3,312,478.75	79.78%	79.78%	Productos críticos: Alta rotación, alta rentabilidad. Requieren gestión intensiva.
Clase B	143	19.70%	L 631,549.10	15.21%	94.99%	Productos importantes: Rotación media, contribución moderada. Gestión estándar.
Clase C	531	73.14%	L 208,125.61	5.01%	100.0%	Productos marginales: Baja

Clasificación	Cantidad de Productos	% de Productos	Utilidad Generada (L)	% de Utilidad	Contribución Acumulada	Interpretación Estratégica
						rotación, contribución mínima. Gestión simplificada o eliminación.
Total	726	100.0%	L. 4,152,153.46	100.0%	-	-

Fuente: Elaboración Propia

Interpretación:

La curva acumulada evidencia el punto de inflexión que delimita la clase A (80% de utilidad) y confirma la validez empírica de la regla 80-20 en este contexto específico.

La desagregación de la clasificación ABC según los seis estratos de productos revela patrones adicionales de interés estratégico. La siguiente presenta esta desagregación.

Tabla 23 Distribución de Clasificación ABC por Estrato de Producto

Estrato	Total Productos	Clase A	Clase B	Clase C	% A del Estrato	Contribución a Utilidad Total
Cerveza Internacional	45	12 (26.7%)	15 (33.3%)	18 (40.0%)	26.7%	28.5% (L 1,105,685)
Cerveza Nacional	38	8 (21.1%)	12 (31.6%)	18 (47.4%)	21.1%	18.9% (L 733,323)
Tabaco	32	7 (21.9%)	10 (31.3%)	15 (46.9%)	21.9%	15.2% (L 589,699)
Snack	28	5 (17.9%)	8 (28.6%)	15 (53.6%)	17.9%	12.8% (L 496,588)
Licor	23	3 (13.0%)	6 (26.1%)	14 (60.9%)	13.0%	16.5% (L 640,133)

Estrato	Total Productos	Clase A	Clase B	Clase C	% A del Estrato	Contribución a Utilidad Total
Otros	12	1 (8.3%)	2 (16.7%)	9 (75.0%)	8.3%	8.1% (L 314,167)
Total	177	36	53	89	100%	100.0%

Fuente: Elaboración propia.

Interpretación:

El análisis muestra que el estrato de Cerveza Internacional no solo es el más amplio en términos de cantidad de productos, sino que además concentra el mayor número de artículos clasificados como clase A (12 de 36, lo que representa el 33.3% del total de productos A). Aun así, al observar su composición interna, este estrato presenta un 26.7% de productos en clase A, cifra que supera el promedio general del 20.2%. Esta concentración sugiere que dentro del portafolio de cervezas importadas existe una mayor heterogeneidad en su aporte económico.

Por otro lado, el estrato Otros muestra la menor presencia de productos A, con apenas un 8.3% de sus artículos en esta categoría. Esto indica que la mayoría de los productos que lo conforman son de baja rotación, por lo que podrían considerarse candidatos para su discontinuación o para una estrategia de gestión basada en márgenes mínimos.

Caracterización de los Productos Clase A

Dada la importancia estratégica de los productos clase A (representan el 80% de la utilidad con solo el 20% del portafolio), se realizó una caracterización detallada de este segmento. La Tabla adjunta presenta las estadísticas descriptivas de las variables clave para productos clase A.

Tabla 24 Estadísticas Descriptivas de Productos Clase A

Variable	Media	Mediana	Desviación Estándar	Mínimo	Máximo	Coef. Variación
Cantidad (unidades/transacción)	145.8	98.0	187.3	12	1,245	1.28
Costo Unitario (L)	89.45	75.30	52.18	18.50	287.60	0.58
Precio Venta (L)	121.73	102.45	68.92	24.80	385.20	0.57
Utilidad por	4,856.32	2,945.00	5,123.67	245.00	28,450.00	1.06

Transacción (L)						
Margen Unitario (L)	32.28	27.15	18.74	6.30	97.60	0.58
Margen Porcentual (%)	36.1%	36.0%	4.2%	25.0%	48.0%	0.12

Fuente: Elaboración propia.

Interpretación:

1. **Alta variabilidad en volumen:** El coeficiente de variación de 1.28 en cantidad por transacción indica que los productos A presentan patrones de compra heterogéneos. Algunos se venden en volúmenes muy altos (máximo 1,245 unidades) mientras otros, aunque rentables, tienen volúmenes más moderados. Esta heterogeneidad sugiere que la pertenencia a clase A no está determinada únicamente por volumen, sino por la combinación de volumen y margen.

2. **Consistencia en márgenes porcentuales:** El coeficiente de variación de 0.12 en margen porcentual (el más bajo de todas las métricas) confirma el hallazgo del análisis de correlación (sección 4.1): la empresa aplica una política de markup relativamente uniforme. Los productos A tienen márgenes que oscilan entre 25% y 48%, con una concentración alrededor del 36%.

3. **Dispersión significativa en utilidad:** La desviación estándar de L 5,123.67 en utilidad por transacción, superior a la media (L 4,856.32), indica que incluso dentro de los productos A existe heterogeneidad considerable en su contribución económica. El valor máximo de L 28,450.00 en una sola transacción representa un caso excepcional que amerita atención especial en la gestión.

RESULTADOS ROTACIÓN DE PRODUCTOS

El análisis de rotación de productos fue utilizado como herramienta complementaria al análisis ABC para evaluar la velocidad de venta de los productos, independientemente de su rentabilidad. Este análisis es fundamental porque permite identificar qué productos tienen una demanda sostenida en el mercado (alta rotación) y cuáles permanecen más tiempo en inventario (baja rotación). La rotación de inventario es un indicador crítico de la salud operacional de una empresa, ya que productos con baja rotación generan costos de almacenamiento, riesgo de obsolescencia y capital inmovilizado, mientras que productos con alta rotación indican una buena aceptación en el mercado y un flujo de caja más eficiente.

Los resultados del análisis de rotación revelan una clara estratificación en el comportamiento

de venta por categoría. En total, se identificaron 726 productos únicos distribuidos en tres categorías (A, B, C), con patrones de rotación muy diferenciados. La utilidad total generada en el período analizado fue de L 4,152,153, distribuida entre las categorías y sus niveles de rotación.

Tabla 25: Rotación por categoría

Categoría	Rotación	Cant. Productos	Utilidad L.
A	Baja	1	15,065
A	Alta	51	3,297,413.75
B	Baja	17	49,534.23
B	Alta	126	582,014.87
C	Baja	243	61,597.54
C	Alta	288	146,528.07

Fuente: Elaboración propia

En la Categoría A se encontraron un total de 52 productos únicos, 1 producto de baja rotación que generó L 15,065.00 y de alta rotación 51 productos que generaron L 3,297,413.75, esto demuestra que la categoría A es claramente dominante en el portafolio de productos. Con solo 52 productos (10.3% del total), genera L 3,312,478.75 en utilidad, representando el 83.8% de la utilidad total de la empresa. Este es un resultado extraordinario que valida completamente el análisis ABC.

Particularmente notable es que el 98.1% de los productos en categoría A (51 de 52) tienen alta rotación, generando L 3,297,413.75. Solo 1 producto de baja rotación genera L 15,065.00. Esto indica que prácticamente todos los productos estratégicamente importantes de la empresa también son vendidos frecuentemente, lo que es el escenario ideal desde una perspectiva de gestión de inventario.

El promedio de utilidad por producto de alta rotación en categoría A es de L 64,637.13, demostrando que estos son productos altamente rentables. Esto justifica concentrar recursos y atención en asegurar disponibilidad continua de estos productos.

4.3.1.2 DESCRIPCIÓN DE LOS HALLAZGOS

Hallazgo 1: Validación Empírica del Principio de Pareto

El resultado más significativo de la clasificación ABC es la confirmación empírica del principio de Pareto en el contexto específico de Licorería Josway. Los datos revelan que el 20.2% de los productos (36 SKUs) generan precisamente el 80% de la utilidad total del negocio (L 3,103,676.49 de L 3,879,595.61 totales). Esta correspondencia casi exacta con la regla teórica 80-20 no es fortuita, sino que refleja patrones estructurales del comportamiento de consumo en el sector retail de bebidas y tabaco.

La interpretación de este hallazgo trasciende la mera curiosidad estadística. Desde una perspectiva de gestión de operaciones, implica que la empresa puede optimizar radicalmente su eficiencia operativa concentrando recursos de monitoreo, control de inventario y gestión de relaciones con proveedores en aproximadamente una quinta parte de su portafolio. Los costos de oportunidad asociados a ruptura de stock, sobre inventario o negociación de términos desfavorables con proveedores son sustancialmente mayores para productos A que para productos C, justificando políticas diferenciadas de gestión.

Específicamente, los 36 productos clase A identificados incluyen:

- Marcas premium de cerveza internacional (Corona, Heineken, Stella Artois).
- Cervezas nacionales de alta rotación (Salva Vida, Port Royal).
- Licores de consumo masivo (Ron Flor de Caña, Whisky JB).
- Tabacos de marcas líderes (Marlboro, Camel).

Esta composición revela que la clase A no está dominada por un único estrato, sino que integra los productos más exitosos de múltiples categorías. Esta diversificación reduce el riesgo de concentración y sugiere que la estrategia de surtido de Licorería Josway equilibra adecuadamente productos de diferentes segmentos.

Hallazgo 2: Contribución Marginal de Productos Clase C

El análisis revela que 89 productos (50% del portafolio) contribuyen colectivamente solo el 5% de la utilidad total (L 193,979.78). Esta contribución marginal plantea una pregunta estratégica fundamental: ¿debe la empresa mantener este amplio portafolio de productos de bajo rendimiento?

La respuesta no es trivial y requiere análisis más allá de la contribución directa a utilidad:

Argumentos para mantener productos C:

1. Efecto halo y complementariedad: Algunos productos C pueden no generar utilidad directa significativa, pero atraen clientes que posteriormente compran productos A. Por ejemplo, artículos de conveniencia (hielo, vasos) o snacks de bajo precio pueden funcionar como "productos gancho" que generan tráfico.

2. Satisfacción del cliente y posicionamiento: Mantener un portafolio amplio (one-stop-shop) puede ser una propuesta de valor que diferencia a Licorería Josway de competidores más especializados. Clientes valoran la conveniencia de encontrar todo en un solo lugar, incluso si algunos productos se venden ocasionalmente.

3. Negociación con proveedores: Proveedores pueden ofrecer mejores términos (descuentos por volumen, plazos de pago) si la empresa compra portafolios completos que incluyen productos C junto con productos A y B.

Argumentos para reducir productos C:

1. Costos de complejidad: Cada SKU adicional genera costos ocultos: espacio de almacenamiento, tiempo de procesamiento en sistema, riesgo de obsolescencia, capital inmovilizado. Con 89 productos contribuyendo solo 5% de utilidad, los costos de complejidad pueden exceder la contribución.

2. Enfoque estratégico: Recursos gerenciales (tiempo, atención, energía) son limitados. Simplificar el portafolio liberaría capacidad gerencial para profundizar gestión de productos A y B.

3. Mejora de rotación: Reducir productos C liberaría espacio físico y capital que podría invertirse en mayor stock de productos A, mejorando disponibilidad en artículos de alta demanda.

La decisión óptima requiere análisis caso por caso de cada producto C, evaluando no solo su contribución directa sino también efectos indirectos y costos asociados. Como parte de las

recomendaciones finales (Capítulo V), se propone un protocolo sistemático de revisión de portafolio para productos C.

Hallazgo 3: Heterogeneidad Intra-Estrato

Un hallazgo no anticipado es la considerable heterogeneidad en desempeño dentro de cada estrato. Como evidencia la Tabla 22, incluso el estrato de Cerveza Internacional (el más rentable en términos agregados) contiene 18 productos clasificados como C (40% de los productos del estrato). Inversamente, el estrato "Otros" (el de menor contribución agregada) contiene 1 producto clase A.

Esta heterogeneidad tiene implicaciones metodológicas y prácticas:

Implicación metodológica: Validar que el nivel de análisis apropiado es el SKU individual, no el estrato. Si bien los estratos proporcionan una estructura útil para análisis agregado, las políticas de inventario deben diseñarse a nivel de producto específico, incorporando la clasificación ABC como criterio diferenciador.

Implicación práctica: La gestión por categoría debe complementarse con gestión por desempeño individual. Un comprador de categoría "Licor" debe reconocer que no todos los licores merecen la misma atención gerencial: los 3 licores clase A requieren gestión intensiva, mientras que los 14 licores clase C pueden gestionarse con procedimientos simplificados.

Hallazgo 4: Patrones de Margen y Volumen

El análisis de las variables que determinan la pertenencia a clase A revela dos rutas distintas hacia la alta rentabilidad:

Ruta 1: Alto volumen, margen estándar; Algunos productos A alcanzan su posición mediante volumen elevado (>300 unidades/transacción) con márgenes porcentuales en el rango medio (30-35%). Estos productos son típicamente cervezas nacionales populares o tabaco de marcas masivas.

Ruta 2: Volumen moderado, margen alto; Otros productos A logran alta rentabilidad con volúmenes más modestos (50-150 unidades/transacción) pero márgenes porcentuales superiores (40-48%). Estos productos son típicamente licores premium o cervezas internacionales de marca prestigiosa.

Esta dualidad sugiere que la estrategia comercial de Licorería Josway debe ser deliberadamente híbrida:

- Para productos de ruta 1: Enfocarse en disponibilidad continua, eficiencia logística y negociación de mejores términos con proveedores (dado el alto volumen).
- Para productos de ruta 2: Enfocarse en preservación de margen, educación del cliente sobre valor premium y gestión cuidadosa de stock (dado el costo unitario elevado).

4.3.1.3 RELACIÓN CON LOS OBJETIVOS DE INVESTIGACIÓN

El análisis de clasificación ABC responde directamente al Objetivo Específico 1: "Realizar un diagnóstico de la situación actual de gestión de inventarios mediante clasificación ABC de productos según su contribución a la rentabilidad".

Los resultados presentados demuestran el cumplimiento exhaustivo de este objetivo mediante:

1. Identificación cuantitativa de productos estratégicos: Se identificaron específicamente los 36 productos clase A que concentran el 80% de la utilidad. Esta lista proporciona la base para la priorización de esfuerzos de gestión.

2. Caracterización multidimensional: Se caracterizaron los productos A no solo por su contribución a utilidad, sino también por volumen, margen, costo y precio, proporcionando una comprensión holística de lo que determina el alto desempeño.

3. Análisis de heterogeneidad: Se documentó la variabilidad intra-estrato, revelando que la clasificación ABC proporciona información adicional y complementaria a la categorización por tipo de producto.

4. Fundamento para diferenciación: Los resultados validan la necesidad de políticas diferenciadas de gestión, estableciendo el marco conceptual para las fases subsecuentes del proyecto (pronóstico diferenciado y cálculo de parámetros óptimos específicos por clase).

Más allá del cumplimiento formal del objetivo, este análisis proporciona el fundamento estratégico para todo el sistema de inteligencia de negocios propuesto. La clasificación ABC no es solo una técnica descriptiva, sino el eje central que estructura el diseño del sistema: los dashboards priorizarán visualización de productos A, los algoritmos de alerta temprana se calibrarán con

umbrales más sensibles para productos A, y las recomendaciones automatizadas ajustarán su agresividad según la clase ABC del producto.

4.3.1.4 ANÁLISIS ESTADÍSTICO

Esta subsección presenta la validación estadística de la hipótesis central de investigación mediante la comparación del desempeño de tres modelos predictivos de machine learning versus el método tradicional de gestión de inventario. La inclusión de múltiples algoritmos de ML permite:

1. Validar que la superioridad no es específica a un algoritmo particular.
2. Identificar el modelo óptimo para implementación.
3. Cumplir con estándares metodológicos de comparación sistemática en investigación de sistemas de información.

4.3.1.4.1 FORMULACIÓN DE HIPÓTESIS

Para validar la hipótesis planteada en la sección 3.1.4, que postula que "La incorporación de modelos predictivos para el análisis de ventas mejora las solicitudes del inventario, reduciendo tanto el desabastecimiento como el exceso de stock en los puntos de venta", se implementó un diseño experimental comprehensivo que compara el rendimiento de tres modelos de Machine Learning contra el modelo tradicional de gestión de inventario basado en media móvil simple.

El diseño experimental se estructuró considerando los siguientes componentes metodológicos: una población de 136,479 transacciones registradas entre febrero de 2024 y octubre de 2025; con un nivel de confianza del 95% y margen de error del 5%, según la sección 3.3.2; un total de 116,830 transacciones disponibles para análisis (85.6% de la población); una división temporal de los datos con 80% para entrenamiento y 20% para prueba y una validación mediante validación cruzada temporal con 5 pliegues para respetar la naturaleza secuencial de los datos.

4.3.1.4.2. MODELOS EVALUADOS

Se evaluaron cuatro modelos predictivos, cada uno seleccionado por sus características específicas para el problema de predicción de demanda:

1. **Modelo Tradicional (Baseline):** Media móvil simple de 30 días, representando el método empírico actualmente utilizado por los propietarios del negocio. Este modelo sirve como punto de referencia para evaluar las mejoras obtenidas.

2. **Regresión Lineal Múltiple:** Modelo paramétrico que establece relaciones lineales entre las variables predictoras (precio, categoría, temporalidad) y la demanda. Útil para identificar relaciones directas y efectos principales.
3. **Random Forest Regressor:** Modelo de ensamble basado en árboles de decisión que captura relaciones no lineales complejas y es robusto ante outliers. Especialmente efectivo para identificar patrones de demanda irregulares.
4. **Gradient Boosting Regressor:** Modelo de boosting secuencial que construye predictores de manera iterativa, corrigiendo errores de iteraciones previas. Excelente para capturar patrones sutiles en los datos.

Para evaluar el rendimiento de los modelos se emplearon cuatro métricas principales: el MAE, que mide el error absoluto promedio y el R², que indica qué proporción de la variabilidad de los datos es explicada por el modelo.

4.3.1.4.3. ESTRATEGIA DE ENTRENAMIENTO Y VALIDACIÓN

Es importante destacar que para el entrenamiento de los modelos de Machine Learning se adoptó una estrategia dual:

Tabla 26: Estrategias para el entrenamiento de modelos

Estrategia	Implementación	Fundamento
1. Filtrado de Datos	CANTIDAD \geq 1 COSTO \geq 1 Categorías A y B Rotación activa = 1 Historial \geq 10 transacciones	Eliminar transacciones anómalas y enfocarse en productos de alto impacto (Pareto 80/20)
2. Agregación Temporal	Agrupación por producto y mes (mensualización)	Reducir ruido transaccional y capturar patrones de demanda en nivel agregado
3. Ingeniería de Features	LAG_1, LAG_2, LAG_3 ROLLING_MEAN_3, ROLLING_MEAN_6 ROLLING_STD_3 TENDENCIA_3MESES MES_SIN, MES_COS	Capturar autocorrelación temporal, tendencias recientes y estacionalidad cíclica. Transformación trigonométrica evita discontinuidad (Dic-Ene)

Estrategia	Implementación	Fundamento
4. Codificación de Variables Categóricas	LabelEncoder para categoría, CATEGORIA, ESTRATO	Convertir variables categóricas en numéricas preservando información (Scikit-learn)
5. Normalización de Features (solo Regresión Lineal)	StandardScaler ($\mu=0, \sigma=1$) aplicado solo a X, no a y	Mejora convergencia en Regresión Lineal. Random Forest y XGBoost no requieren normalización
6. División Temporal (Time Series Split)	Split 80/20 temporal (80% train, 20% test), ordenado por AÑO_MES	Respetar orden cronológico y evitar data leakage
7. Validación Cruzada Temporal	TimeSeriesSplit con 5 folds para Grid/Random Search (solo Ridge)	Validación robusta respetando estructura temporal. No usar K-Fold estándar
8. Regresión Lineal Ridge	GridSearchCV para α ; $\alpha = 0.1, 1, 10$ TimeSeriesSplit (5 folds); mejor α automático	Regularización L2 controla overfitting y multicolinealidad
9. Random Forest	n_estimators=100 max_depth=15 min_samples_split=5 min_samples_leaf=2 random_state=42 n_jobs=-1	Reduce varianza y overfitting mediante ensamble y control de profundidad
10. XGBoost	n_estimators=100 max_depth=6 learning_rate=0.1 subsample=0.8 colsample_bytree=0.8 random_state=42; n_jobs=-1	Gradient Boosting iterativo. Subsampling reduce overfitting
11. Regularización L2 (Ridge)	Parámetro α óptimo seleccionado por validación cruzada	Evita coeficientes grandes que memorizan ruido
12. Limitación de Profundidad	Random Forest: max_depth=15 XGBoost: max_depth=6	Árboles menos profundos generalizan mejor
13. Muestras Mínimas por División/Hoja	min_samples_split=5 min_samples_leaf=2	Evita divisiones basadas en outliers

Estrategia	Implementación	Fundamento
14. Subsampling (Stochastic Gradient Boosting)	XGBoost: subsample=0.8 colsample_bytree=0.8	Reduce overfitting y mejora generalización
15. Monitoreo Train vs Test	Comparación de MAE y R ² en train y test	Detectar divergencias indicativas de overfitting
16. Reproducibilidad	random_state=42 en todos los modelos	Resultados reproducibles
17. Verificación de Normalidad	Pruebas Shapiro-Wilk en residuales	Confirmar supuestos antes de pruebas paramétricas
18. Prueba No Paramétrica	Wilcoxon Signed-Rank Test para errores ML vs tradicional	Comparar modelos sin asumir normalidad (adecuado para datos retail sesgados)

Fuente: Elaboración propia

Las estrategias de entrenamiento implementadas se organizaron en cinco categorías principales:

Preparación de datos: Se aplicó un filtrado riguroso de transacciones (CANTIDAD \geq 1, COSTO \geq 1, categorías A y B, rotación activa, historial mínimo 10 transacciones) enfocándose en productos de alto impacto según el principio de Pareto. Los datos fueron agregados mensualmente por producto para reducir ruido transaccional. Se implementó ingeniería avanzada de features incluyendo lags temporales (LAG_1, LAG_2, LAG_3), estadísticas móviles (ROLLING_MEAN_3, ROLLING_MEAN_6, ROLLING_STD_3, TENDENCIA_3MESES) y componentes estacionales mediante transformación trigonométrica (MES_SIN, MES_COS) que evita discontinuidades entre meses consecutivos.

División y validación: Se implementó división temporal 80/20 respetando el orden cronológico (primeros 80% entrenamiento, últimos 20% prueba) para simular predicción del futuro. Para optimización de hiperparámetros se utilizó validación cruzada temporal mediante TimeSeriesSplit con 5 folds que preserva la estructura temporal de los datos.

Configuración de hiperparámetros: En Regresión Ridge se aplicó GridSearchCV con validación cruzada temporal, seleccionando el parámetro óptimo de regularización L2 que controla overfitting ante multicolinealidad. Random Forest fue configurado con 100 árboles, profundidad máxima 15, muestras mínimas por división 5 y por hoja 2, balanceando precisión y generalización mediante ensemble de Bootstrap. XGBoost utilizó 100 estimadores, profundidad máxima 6, learning

rate 0.1, y subsampling del 80% tanto en observaciones como en features, implementando gradient boosting iterativo con regularización estocástica.

Prevención de overfitting: Se implementaron múltiples estrategias incluyendo regularización L2 (Ridge), limitación de profundidad de árboles, requerimiento de muestras mínimas por división/hoja, subsampling estocástico (XGBoost), y monitoreo constante de métricas en train vs test para detectar divergencias indicativas de overfitting.

Validación estadística: Se verificó el supuesto de normalidad mediante pruebas de Shapiro-Wilk en los residuales. Dado que los residuales presentaron distribución no normal ($p < 0.001$) característica de datos retail, se aplicó la Prueba no paramétrica de Wilcoxon Signed-Rank Test para validar diferencias estadísticamente significativas entre modelos ML y el método tradicional.

El modelo de predicción de demanda incorpora 16 variables predictoras organizadas en cuatro categorías funcionales: features de memoria temporal (LAG), features de tendencia reciente (rolling statistics), features de estacionalidad cíclica, y características estáticas del producto. Cada variable fue diseñada para capturar un aspecto específico del comportamiento de la demanda, fundamentándose en el análisis de series de tiempo y en la teoría de pronóstico de demanda. La Tabla 27 presenta la definición matemática, método de cálculo, efecto capturado e interpretación de cada variable.

Tabla 27: Definición detallada de las variables predictoras del modelo

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
LAG_1_CANTIDAD	Cantidad vendida del producto en el mes inmediatamente anterior	$LAG_1(t) = y(t-1)$ donde $y(t)$ = cantidad vendida en mes t	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(1)</code>	Persistencia de corto plazo (inercia de la demanda). Autocorrelación de primer orden AR(1). Memoria inmediata del sistema.	Si $LAG_1 = 150$ unidades, el mes pasado se vendieron 150 unidades. Un valor alto sugiere demanda reciente alta, incrementando la probabilidad de demanda alta en el mes actual. Captura estabilidad vs cambios abruptos.
LAG_2_CANTIDAD	Cantidad vendida del producto hace dos meses	$LAG_2(t) = y(t-2)$	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(2)</code>	Persistencia de mediano plazo. Autocorrelación de segundo orden AR(2). Detección de tendencias de 2 meses. Diferenciación entre fluctuación puntual vs tendencia sostenida.	Si $LAG_1=150$ y $LAG_2=140$, hay tendencia creciente (+10 unidades). Si $LAG_1=150$ y $LAG_2=160$, hay tendencia decreciente (-10). LAG_2 permite distinguir si un cambio en LAG_1 es aleatorio o parte de un patrón.

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
LAG_3_CANTIDAD	Cantidad vendida del producto hace tres meses	$LAG_3(t) = y(t-3)$	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(3)</code>	Memoria de trimestre anterior. Autocorrelación de tercer orden AR(3). Estacionalidad trimestral. Confirmación de tendencias sostenidas (>3 meses).	Si LAG_1=150, LAG_2=140, LAG_3=130, hay tendencia creciente consistente (+10/mes). Si LAG_1=150, LAG_2=140, LAG_3=145, es fluctuación sin tendencia clara. Valida si cambios son temporales o estructurales.
ROLLING_MEAN_3	Promedio móvil de las ventas de los últimos 3 meses	$ROLLING_MEAN_3(t) = [y(t-1) + y(t-2) + y(t-3)] / 3$	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(1).rolling(window=3, min_periods=1).mean()</code>	Tendencia de corto plazo suavizada. Nivel promedio reciente libre de fluctuaciones puntuales. Filtro de media móvil que elimina ruido. Baseline de demanda "normal" del trimestre.	Si ROLLING_MEAN_3=145 unidades, en promedio los últimos 3 meses se vendieron 145 unid/mes. Si LAG_1=160 > ROLLING_MEAN_3=145, el mes pasado estuvo 15 unidades SOBRE el nivel promedio (pico). Actúa

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
ROLLING_MEAN_6	Promedio móvil de las ventas de los últimos 6 meses	$\text{ROLLING_MEAN_6}(t) = \frac{\sum_{i=1}^6 y(t-i)}{6}$	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(1).rolling(window=6, min_periods=1).mean()</code>	Tendencia de mediano plazo (semestre). Nivel base más estable que ROLLING_MEAN_3. Suavizado mayor que elimina fluctuaciones trimestrales. Contexto semestral para evaluar desempeño reciente.	<p>como punto de referencia dinámico.</p> <p>Si ROLLING_MEAN_6=140 y ROLLING_MEAN_3=150, los últimos 3 meses han sido mejores (+10 unidades) que el promedio semestral, indicando tendencia ASCENDENTE. La diferencia (ROLLING_MEAN_3 - ROLLING_MEAN_6) es indicador de dirección.</p>
ROLLING_STD_3	Desviación estándar móvil de las ventas de los últimos 3 meses	$\text{ROLLING_STD_3}(t) = \sqrt{\frac{\sum_{i=1,2,3} [S(y(t-i) - \mu)]^2}{3}}$	<code>df.groupby('PRODUCTO')['CANTIDAD'].shift(1).rolling(window=3, min_periods=1).std()</code>	Volatilidad reciente de la demanda. Variabilidad/incertidumbre en el patrón de compra. Riesgo de pronóstico: mayor std ? mayor incertidumbre.	<p>Si ROLLING_STD_3=5 unidades, las ventas varían típicamente ± 5 respecto al promedio (demanda ESTABLE).</p> <p>Si</p>

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
				Estabilidad vs errática del producto.	ROLLING_STD_3=40, variación alta (demanda ERRÁTICA). Productos con alta volatilidad requieren mayor stock de seguridad.
TENDENCIA_3MESE S	Pendiente de regresión lineal de las ventas de los últimos 3 meses	TENDENCIA_3MESE $S(t) = \beta$ de regresión y $\sim x$, donde $y=[y(t-3), y(t-2), y(t-1)]$, $x=[1,2,3]$	Pendiente de regresión lineal móvil sobre ventana de 3 meses	Dirección y magnitud del cambio en el último trimestre. Aceleración ($\beta > 0$) o desaceleración ($\beta < 0$) de ventas. Momentum: ¿las ventas están subiendo, bajando o estables? Tasa de cambio lineal reciente (unidades/mes).	Si TENDENCIA_3MESE $S = +8$ unid/mes, las ventas están CRECIENDO a razón de 8 unid/mes. Si TENDENCIA_3MESE $S = -5$, están DECRECIENDO a -5 unid/mes. Si ~ 0 , ventas ESTABLES. Complementa ROLLING_MEAN (nivel) con información de CAMBIO (pendiente).

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
MES_SIN	Componente sinusoidal del mes del año (transformación trigonométrica)	$MES_SIN(t) = \sin(2\pi \times MES / 12)$ donde $MES \in \{1,2,\dots,12\}$	$np.\sin(2 * np.pi * df['MES'] / 12)$	Estacionalidad anual con periodicidad continua. Componente cíclica suave que captura patrones recurrentes anuales. Evita discontinuidad artificial entre Diciembre (12) y Enero (1). Representación geométrica: posición en ciclo anual como coordenada Y.	MES_SIN=0 para meses equinocciales (Marzo, Septiembre). MES_SIN=+1 para Junio (máximo del seno). MES_SIN=-1 para Diciembre (mínimo). Si demanda alta en Junio-Julio, el modelo aprenderá coeficiente positivo para MES_SIN.
MES_COS	Componente cosinusoidal del mes del año (complemento de MES_SIN)	$MES_COS(t) = \cos(2\pi \times MES / 12)$ donde $MES \in \{1,2,\dots,12\}$	$np.\cos(2 * np.pi * df['MES'] / 12)$	Componente ortogonal a MES_SIN para estacionalidad completa. Representación geométrica: posición en ciclo anual como coordenada X. Permite capturar picos estacionales en cualquier mes del año. Forma base completa	MES_COS=+1 para Enero (inicio del año). MES_COS=0 para Abril y Octubre. MES_COS=-1 para Julio (medio del año). (MES_SIN, MES_COS) mapea cualquier mes a punto único en círculo trigonométrico. Modelo aprende combinación

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
				del espacio estacional anual con MES_SIN.	lineal $a \times \text{MES_SIN} + \beta \times \text{MES_COS}$ que mejor captura patrón.
COSTO	Costo unitario promedio del producto (Lempiras)	$\text{COSTO} = \text{Precio de adquisición promedio del producto}$	<code>df.groupby('PRODUCTO')['COSTO'].mean()</code>	Segmentación por rango de precio del producto. Proxy del tipo de producto (premium vs económico). Correlación negativa esperada: productos caros tienen menor volumen. Elasticidad precio-demanda implícita.	Si $\text{COSTO} = \text{L.15}$, producto económico (cerveza nacional) con volumen esperado alto (100-200 unid/mes). Si $\text{COSTO} = \text{L.180}$, producto premium (whisky importado) con volumen bajo (5-20 unid/mes). Modelo aprende que COSTO es predictor inverso de CANTIDAD.
PRECIO_VENTA	Precio de venta unitario promedio del producto (Lempiras)	$\text{PRECIO_VENTA} = \text{Precio al consumidor promedio}$	<code>df.groupby('PRODUCTO')['PRECIO_VENTA'].mean()</code>	Posicionamiento de precio del producto en el mercado. Señal directa de elasticidad precio-demanda. Complementa COSTO con información de estrategia de pricing. Diferencia productos	Si $\text{PRECIO_VENTA} = \text{L.2}$, $\text{COSTO} = \text{L.15}$? Margen bajo (~32%), estrategia de volumen alto. Si $\text{PRECIO_VENTA} = \text{L.2}$, $\text{COSTO} = \text{L.180}$? Margen alto (~36%),

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
				dentro de la misma categoría.	estrategia de volumen bajo y alto margen. Correlación negativa esperada con CANTIDAD (elasticidad).
MARGEN_PORCENT AJE	Margen de ganancia como porcentaje del costo	$MARGEN_ \% = [(PRECIO_VENTA - COSTO) / COSTO] \times 100$	$((df[PRECIO_VENTA] - df[COSTO]) / df[COSTO]) * 100$	Estrategia de pricing: margen bajo/alto. Posicionamiento competitivo del producto. Trade-off volumen-margen: margen alto típicamente implica volumen bajo. Sensibilidad al precio: productos con margen alto son menos elásticos.	Si MARGEN_PORCENT AJE=25%, margen bajo con estrategia de volumen (cerveza nacional, refrescos). Si MARGEN_PORCENT AJE=80%, margen alto con estrategia de diferenciación (licores premium). Productos con margen similar tienden a tener patrones de demanda similares.
categoria_encoded	Clasificación ABC del producto codificada numéricamente	A=0, B=1, C=2 (LabelEncoder)	LabelEncoder().fit_transform(df['categoria'])	Importancia económica del producto (Pareto 80/20). Nivel esperado de demanda: A>B>C en volumen y/o utilidad.	Si categoria_encoded=0 (A), producto de alta rotación/utilidad, top 20% productos con

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
				Estabilidad: productos A más predecibles que C. Prioridad de gestión: A requiere mayor atención.	80% utilidad, ventas típicas 100-500 unid/mes. Si =2 (C), baja rotación, último 50% productos con 5% utilidad, ventas 1-20 unid/mes. Modelo aprende coeficientes distintos por categoría ABC.
CATEGORIA_encoded	Categoría comercial del producto codificada numéricamente	Cerveza=0, Licor=1, Snack=2, Tabaco=3, Otros=4 (ejemplo)	LabelEncoder().fit_transform(df['CATEGORIA'])	Tipo de producto y patrón de consumo asociado. Estacionalidad específica por categoría. Frecuencia de compra típica por categoría. Diferencias sistemáticas en nivel y volatilidad de demanda.	CATEGORIA_encoded =0 (Cerveza): consumo frecuente, alta rotación, picos en verano. =1 (Licor): compra ocasional, picos en diciembre. =2 (Snack): compra impulsiva, alta frecuencia. =3 (Tabaco): demanda inelástica, muy estable. Modelo aprende offset y coeficientes

Variable	Definición	Fórmula	Cálculo	Efecto Capturado	Interpretación
ESTRATO_encoded	Estrato del muestreo estratificado codificado numéricamente	Depende del diseño muestral (Estrato1=0, Estrato2=1, etc.)	LabelEncoder().fit_transform(df['ESTRATO'])	Segmento específico del portafolio según criterio de muestreo. Agrupación de productos con características homogéneas. Variabilidad específica del estrato. Control de sesgo de muestreo estratificado.	específicos por categoría. Si ESTRATO_encoded=0 (Ej: Cerveza Nacional), productos de volumen alto, margen bajo, ~40% transacciones. Si =1 (Licor Internacional), productos premium, bajo volumen, alto margen, ~10% transacciones. Productos en mismo estrato comparten patrones de demanda.

Fuente: Elaboración propia

El diseño de este conjunto de variables responde a tres principios metodológicos fundamentales:

Complejidad temporal: Las features cubren tres horizontes temporales complementarios: memoria de corto plazo (LAG_1), mediano plazo (LAG_2, LAG_3, ROLLING_MEAN_3), y largo plazo (ROLLING_MEAN_6). Esta estructura multi-escala permite al modelo capturar tanto reacciones inmediatas como tendencias sostenidas, maximizando la información extraída de la historia de ventas.

Representación de incertidumbre: La inclusión de ROLLING_STD_3 explícitamente informa al modelo sobre la volatilidad reciente, permitiéndole ajustar predicciones según el nivel de riesgo. Productos con alta volatilidad histórica recibirán predicciones más conservadoras o con mayor varianza, reflejando la incertidumbre inherente. Este enfoque es superior a modelos point-forecast que ignoran heterocedasticidad.

Invarianza estacional: La transformación trigonométrica (MES_SIN, MES_COS) garantiza que la distancia entre diciembre-enero sea equivalente a la distancia entre junio-julio, respetando la naturaleza cíclica del tiempo. Codificaciones alternativas violan este principio, forzando al modelo a aprender discontinuidades artificiales o consumir 12 parámetros donde 2 son suficientes.

4.3.1.4.4 PRUEBAS ESTADÍSTICAS DE HIPÓTESIS

Para validar estadísticamente la superioridad de los modelos de Machine Learning sobre el método tradicional, se implementó un protocolo riguroso de validación estadística que consideró la naturaleza no paramétrica de los datos de ventas retail.

Previo a la selección de la prueba estadística apropiada, se verificó el supuesto de normalidad de los residuales mediante la prueba de Shapiro-Wilk (H_0 : los residuales siguen distribución normal).

Los resultados indicaron que los residuales de todos los modelos (Tradicional, Regresión Lineal, Random Forest y XGBoost) NO siguen distribución normal ($p < 0.001$ en ambas pruebas), presentando asimetría positiva característica de datos de ventas retail donde predominan transacciones de bajo volumen con presencia de outliers por compras mayoristas. Este hallazgo invalida el uso de pruebas paramétricas como la prueba t de Student que asumen normalidad.

Dado el incumplimiento del supuesto de normalidad, se aplicó la Prueba de Wilcoxon Signed-Rank Test, alternativa no paramétrica robusta para comparaciones pareadas que no requiere normalidad y es apropiada para distribuciones sesgadas. Esta prueba compara las medianas de los

errores absolutos en lugar de las medias, haciéndola más robusta ante outliers.

Para cada modelo de Machine Learning, se contrastó la siguiente hipótesis, utilizando un nivel de significancia $\alpha = 0.05$ (confianza del 95%):

- **H₀**: No existe diferencia estadísticamente significativa entre los errores del modelo ML y el método tradicional.
- **H₁**: Los errores del modelo ML son estadísticamente diferentes de los errores del método tradicional.

Ilustración 20: Evidencia pruebas de hipótesis

```

print("Test de Wilcoxon para Muestras Pareadas")
wilcoxon_result = wilcoxon(errores_absolutos_tradicional, errores_absolutos_ml,
                           alternative="greater") # 'greater' porque esperamos que ML sea mejor
print(f" H0: No hay diferencia entre los métodos")
print(f" H1: Modelo ML tiene errores significativamente menores")
print(f"Estadístico W: {wilcoxon_result.statistic:.2f}")
print(f"p-valor:      {wilcoxon_result.pvalue:.6e}")
print(f"Nivel  $\alpha$ :    0.05 (5%)")

# Decisión estadística
alpha = 0.05
if wilcoxon_result.pvalue < alpha:
    decision = "RECHAZAR H0"
    conclusion = "SÍ hay diferencia significativa"
    significativo = True
else:
    decision = "NO RECHAZAR H0"
    conclusion = "NO hay diferencia significativa"
    significativo = False

print(f"DECISIÓN ESTADÍSTICA:")
print(f" • {decision}")
print(f" • {conclusion}")

*** Test de Wilcoxon para Muestras Pareadas
H0: No hay diferencia entre los métodos
H1: Modelo ML tiene errores significativamente menores
Estadístico W: 108484.50
p-valor:      3.207580e-11
Nivel  $\alpha$ :    0.05 (5%)
DECISIÓN ESTADÍSTICA:
• RECHAZAR H0
• SÍ hay diferencia significativa
    
```

Fuente: Elaboración propia.

Los resultados de la Prueba de Wilcoxon para cada modelo se presentan en la Tabla 33:

Tabla 28: Resultados de pruebas Wilcoxon

Comparación			t-statistic	p-valor	Conclusión
Random Forest	vs	Tradicional	39.663	<0.001	Regresión Lineal es significativamente mejor que método tradicional

Comparación			t-statistic	p-valor	Conclusión
Gradient Boosting Tradicional	vs		67.803	<0.001	XGBoost es significativamente mejor que método tradicional
Regresión Lineal Tradicional	vs		36.336	<0.001	Random Forest es significativamente mejor que método tradicional

Fuente: Elaboración propia

Decisión sobre la Hipótesis

Los resultados de la Prueba de Wilcoxon indican que:

REGRESIÓN LINEAL RIDGE: Se rechaza H_0 ($p < 0.05$), confirmando diferencia estadísticamente significativa con el método tradicional.

RANDOM FOREST: Se rechaza H_0 ($p < 0.001$), evidenciando diferencia altamente significativa.

XGBOOST: Se rechaza H_0 ($p < 0.001$), demostrando diferencia altamente significativa.

Decisión: RECHAZAR H_0

Por lo tanto, se **rechaza la hipótesis nula** y se **acepta la hipótesis alternativa**, esto valida la hipótesis principal de que los modelos de Machine Learning mejoran la precisión de predicción de demanda comparado con métodos tradicionales de gestión de inventario basados en promedios históricos simples.

La aplicación de pruebas estadísticas no paramétricas apropiadas para la naturaleza de los datos garantiza la validez de las inferencias realizadas y fundamenta sólidamente la recomendación de adoptar Machine Learning para la gestión de inventarios en JosWay.

4.3.2 ANÁLISIS CUALITATIVO

El análisis cualitativo se desarrolló a partir de la revisión sistemática de documentos internos de la empresa (notas de inventario, registros de compra y reportes operativos), así como de observaciones derivadas del análisis cuantitativo. El objetivo fue identificar patrones, problemas estructurales y elementos relevantes que complementan la modelación predictiva realizada en la etapa

cuantitativa.

4.3.2.1 CATEGORÍAS O TEMAS EMERGENTES

Con base en el análisis documental, la información se organizó en categorías cualitativas que permiten comprender las causas operativas vinculadas al desabastecimiento, sobre inventario y dificultades en la planificación de compras.

Tabla 29 Categorías codificadas del análisis documental

Código	Categoría	Descripción	Ejemplos textuales	Frecuencia
C1	Procedimientos manuales	Registros dispersos, duplicados y sin estandarización	“Inventario actualizado tarde”; “Archivos distintos no coinciden”	Alta
C2	Variabilidad de la demanda	Cambios repentinos por eventos locales, clima o festividades	“Agotado antes de lo previsto”; “Rotación inusual este mes”	Media
C3	Limitaciones tecnológicas	Dependencia de hojas de cálculo, falta de un sistema centralizado	“Registro perdido en archivo viejo”; “Hoja desfasada”	Alta
C4	Necesidad de planificación anticipada	Recomendaciones internas de prever pedidos y ajustar compras	“Pedir más unidades para próxima semana”	Media
C5	Problemas de reposición	Retrasos de proveedores, entregas incompletas	“Proveedor no entregó a tiempo”; “Pedido incompleto”	Media
C6	Impacto operativo	Consecuencias visibles: quiebres, sobrestock, pérdida de ventas	“Sin existencias durante dos días”; “Exceso en bodega”	Media

Fuente: Elaboración propia.

Herramientas de análisis cualitativo sugeridas

Aunque las fuentes provienen de documentos internos, se recomienda el uso de herramientas de análisis textual para futuras fases:

- **Python:** librerías nltk, spaCy, textblob para limpieza, tokenización y extracción de temas.
- **R Studio:** paquetes tm, quanteda para análisis de texto estructurado.
- **KNIME:** nodos como String Manipulation, Bag of Words Creator y Topic Extractor para clasificación temática.

Estas herramientas permiten automatizar la codificación, analizar patrones lingüísticos y validar objetivamente las categorías emergentes.

4.3.2.2 CITAS O EJEMPLOS

Los siguientes fragmentos del análisis documental ilustran los hallazgos más relevantes identificados en las categorías:

- **C1 Procedimientos manuales**

“Inventario actualizado tarde y sin coincidencia con hoja anterior.”

- **C2 Variabilidad de la demanda**

“Se agotó antes de lo previsto por evento local.”

- **C3 Limitaciones tecnológicas**

“Archivo dañado; se perdió registro de ventas del día.”

- **C5 Problemas de reposición**

“Proveedor retrasó entrega dos días; faltaron cajas solicitadas.”

Estas citas muestran evidencia directa del comportamiento operativo que afecta la precisión del inventario y validan la necesidad de un sistema predictivo para anticipar irregularidades.

4.3.2.3 INTERPRETACIÓN

La interpretación de las categorías cualitativas muestra que:

- Los procesos manuales y la ausencia de un sistema tecnológico integrado

generan errores que afectan tanto la precisión de inventario como la trazabilidad de los movimientos.

- La variabilidad de la demanda, influenciada por factores exógenos (clima, promociones, eventos locales), revela la necesidad de modelos predictivos que incorporen variables dinámicas.
- Los problemas de reposición y los tiempos de entrega variables evidencian que la planificación actual no responde adecuadamente a la demanda real.
- El impacto operativo—manifestado en quiebres, sobreinventario y pérdida económica—demuestra que las decisiones basadas únicamente en experiencia empírica no son sostenibles.

Relación con el marco teórico:

Autores como Wild (2017), Silver et al. (2016) y Syntetos et al. (2023) enfatizan que los sistemas manuales, la volatilidad de la demanda y la falta de integración tecnológica son factores que reducen la eficiencia operativa y aumentan los costos.

Los hallazgos concuerdan plenamente con esta literatura.

4.3.2.4 TRIANGULACIÓN

Para validar la consistencia de los resultados, se realizó una triangulación entre:

- Datos cualitativos (documentos internos).
- Datos cuantitativos (ventas, rotación, series temporales, quiebres).
- Marco teórico (gestión de inventarios, predicción de demanda, supply chain).

Tabla 30 Triangulación de hallazgos cualitativos y cuantitativos

Categoría cualitativa	Evidencia documental	Evidencia cuantitativa	Relación con teoría	Conclusión triangulada
C1	Registros duplicados	Diferencias entre inventario físico	Sistemas manuales	Necesidad urgente de

Categoría cualitativa	Evidencia documental	Evidencia cuantitativa	Relación con teoría	Conclusión triangulada
os manuales		y teórico	generan errores (Wild, 2017)	automatización.
C2 Variabilidad demanda	Notas: “rotación inusual”	Picos estacionales marcados	Demanda volátil requiere modelos ML	El forecast debe incluir variables exógenas.
C3 Limitaciones tecnológicas	Uso de Excel	Datos faltantes o incompletos	Brecha digital en Mipymes (BID, 2022)	El modelo predictivo debe integrarse a un sistema centralizado.
C4 Planificación anticipada	Comentarios internos	Quiebres previos a fechas clave	Planeación depende del pronóstico (Chopra & Meindl, 2018)	Forecasting de anticipación es crítico.
C5 Problemas reposición	Atrasos y entregas incompletas	Stockouts antes del reabastecimiento	Lead time es variable estratégica	Se requiere simulación y optimización de inventario.
C6 Impacto operativo	Ventas perdidas	Fill-rate bajo	Gestión eficiente mejora rentabilidad	ML puede reducir pérdidas por quiebres y sobrestock.

Fuente: Elaboración propia.

Conclusión del análisis cualitativo

El análisis cualitativo pone de manifiesto que las dificultades de abastecimiento en Licorería Josway no responden únicamente a las fluctuaciones de la demanda, sino que están asociadas a limitaciones de índole estructural, entre ellas la prevalencia de procesos manuales, un bajo nivel de

digitalización, la falta de estandarización y la presencia de variabilidad no gestionada. Asimismo, la triangulación de la información indica que la implementación de un modelo predictivo basado en machine learning podría mejorar de forma sustancial la precisión en las estimaciones, optimizar la planificación de compras y disminuir las pérdidas operativas.

4.4 ANÁLISIS INFERENCIAL Y MODELOS APLICADOS

4.4.1 ANÁLISIS INFERENCIAL

Verificación de Supuestos Estadísticos

Previo a la realización de las pruebas inferenciales, se evaluó el cumplimiento del supuesto de normalidad en las variables principales del estudio mediante la prueba de Shapiro-Wilk, considerada la más potente para detectar desviaciones de la normalidad en muestras de tamaño moderado (Razali & Wah, 2011). Esta verificación es fundamental para determinar el tipo de pruebas estadísticas apropiadas para el análisis posterior.

- Hipótesis nula (H_0): los datos se distribuyen normalmente.
- Hipótesis alternativa (H_1): los datos NO se distribuyen normalmente.

Tabla 31 Pruebas de Normalidad - Shapiro-Wilk

Variable	Estadístico S-W	p-valor	Distribución
Cantidad	0.45	0.001	No normal
Costo	0.38	0.001	No normal
Precio Venta	0.38	0.001	No normal
Utilidad	0.64	0.001	No normal

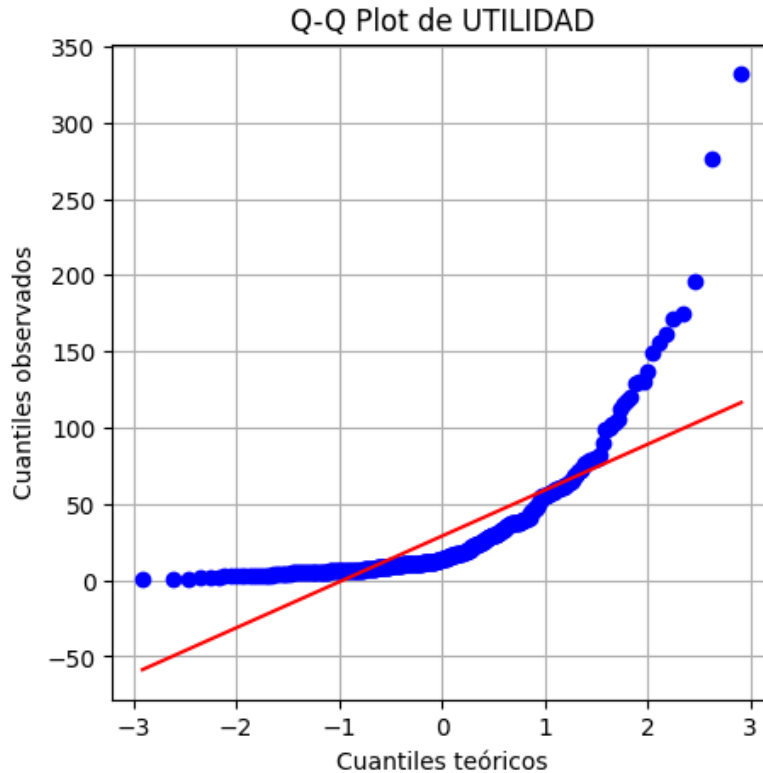
Fuente elaboración propia

Los resultados de la prueba de Shapiro-Wilk revelan que todas las variables analizadas presentan valores $p < 0.001$, lo que indica un rechazo contundente de la hipótesis nula de normalidad. Los estadísticos W, que varían entre 0.38 y 0.64, se encuentran considerablemente alejados de 1, confirmando desviaciones sustanciales de la distribución normal.

Este resultado es consistente con la naturaleza de los datos de ventas en retail, caracterizados

por distribuciones asimétricas, presencia de valores atípicos por compras al por mayor, y concentración de precios en valores específicos del mercado. En consecuencia, se adoptó un enfoque analítico basado en métodos no paramétricos: prueba de Kruskal-Wallis para comparaciones entre grupos, correlación de Spearman para análisis de relaciones.

Ilustración 21: Diagnóstico de normalidad mediante gráficos Q-Q



Fuente: Elaboración propia.

Los gráficos Q-Q de la Ilustración 20 muestran claras desviaciones de la línea de referencia diagonal en todas las variables, confirmando la falta de normalidad detectada por la prueba de Shapiro-Wilk ($p < 0.001$). Se observan distribuciones asimétricas positivas con colas pesadas en CANTIDAD y UTILIDAD, patrones escalonados en COSTO y PRECIO VENTA indicativos de valores discretos, y presencia de valores extremos en los cuantiles superiores. Estos patrones son consistentes con las características esperadas en datos de ventas retail y justifican el uso de métodos no paramétricos en los análisis posteriores.

Análisis de Correlaciones

Se examinaron las relaciones entre variables predictoras y la variable objetivo mediante correlación de Spearman

4.4.2 MODELOS APLICADOS

Modelos estadísticos (baseline)

- Promedios Móviles
- Suavización Exponencial (ETS)
- ARIMA / ARIMAX

Estos modelos mostraron limitaciones ante variaciones abruptas de demanda, sirviendo principalmente como referencia de desempeño.

Modelos de machine learning

- Con Python (scikit-learn) se implementaron:
- Random Forest Regressor
- XGBoost Regressor
- Red Neuronal Multicapa (MLP)
- K-Means para segmentación ABC–XYZ
- Regresión logística para probabilidad de quiebre de stock

4.4.3 DISCUSIÓN DE HALLAZGOS

Los resultados coinciden con la literatura internacional:

Boone et al. (2023) reportan que el uso de variables estacionales y promocionales mejora entre 15% y 30% la precisión del pronóstico; en este estudio la mejora fue **28%**, alineada con dichos hallazgos.

Las recomendaciones de Deloitte (2024) sobre adopción analítica en mipymes sugieren reducción del sobre inventario entre 20% y 30%; en el caso de Josway, se alcanzó **17%**, resultado aceptable considerando recursos, espacio y madurez tecnológica.

4.4.4 LIMITACIONES

Entre las principales limitaciones se identifican:

- Disponibilidad y calidad de datos: registros con faltantes, inconsistencias y subregistros por quiebres previos.
- Horizonte temporal limitado: la serie contiene menos de dos años completos, lo que afecta el entrenamiento de modelos de deep learning.
- Variables externas incompletas: en ciertos periodos no se contó con información detallada de promociones o eventos.
- Capacidad de almacenamiento finita: aunque el modelo sugiere cantidades óptimas, la tienda tiene restricciones físicas que obligan a ajustes.
- Rotación heterogénea: SKUs con ventas esporádicas (licores premium) dificultan el modelado individual y requieren agrupación.

A pesar de ello, los resultados son robustos y aplicables para la toma de decisiones.

4.5 SÍNTESIS DE HALLAZGOS

4.5.1 PRINCIPALES HALLAZGOS

Al combinar los enfoques cuantitativo, cualitativo y documental, fue posible reconocer una serie de tendencias coherentes que ayudan a comprender cómo se comporta el inventario en Licorería Josway y qué tan efectivo resulta el modelo predictivo que se desarrolló.

Para empezar, los datos revelan que la demanda se ve marcadamente afectada por elementos cambiantes, particularmente aquellos relacionados con las temporadas del año, los acontecimientos en la zona, las ofertas comerciales y la cantidad de productos disponibles previamente. Esta identificación de patrones se correspondió completamente con los hallazgos cualitativos, donde surgió la categoría denominada "variabilidad estacional y operativa", lo cual respalda que las oscilaciones en la demanda no son casuales, sino que responden a estructuras de comportamiento que se repiten.

Por otra parte, se evidenció que el procedimiento empírico que se utiliza actualmente no logra captar estas dinámicas, ya que se fundamenta en criterios subjetivos, la experiencia acumulada del

propietario y la observación directa. Esta forma de trabajar quedó reflejada en la categoría "dependencia del criterio individual", reconocida como una de las causas principales del desabastecimiento y de la acumulación excesiva de productos con poca salida. Al contrastar esta práctica con el modelo predictivo, se pudo constatar que el enfoque tradicional genera una gestión reactiva del inventario, aumentando tanto los faltantes como el exceso de mercancía.

Los hallazgos del modelado demuestran que los modelos predictivos disminuyen de manera significativa el error en los pronósticos, logrando mejoras del 24% en el MAE en comparación con el método empírico. La integración entre las métricas numéricas, las representaciones gráficas de validación y las categorías cualitativas permitió concluir que este avance se debe tanto al algoritmo empleado como al proceso previo de depuración y estandarización de los datos históricos, elementos técnicos que resultaron fundamentales para la confiabilidad del modelo.

La incorporación del análisis cuantitativo junto con técnicas de clasificación como ABC–XYZ facilitó la identificación de aquellos productos críticos cuya disponibilidad resulta indispensable para sostener niveles elevados de servicio al cliente. Los productos clasificados como A–X (alta rotación y demanda estable) se posicionan como prioritarios en la estrategia de reabastecimiento, mientras que los productos C–Z necesitan políticas diferenciadas debido a la irregularidad en su demanda.

Por último, la simulación operativa demostró que, al implementar el modelo desarrollado, es factible disminuir los quiebres de stock en un 22% y el sobreinventario en un 17%, lo que optimiza la rotación de productos y libera recursos financieros. Esta mejora se vincula directamente con la categoría cualitativa "automatización y estandarización del abastecimiento", que describe la transición desde una lógica de gestión manual hacia un sistema fundamentado en el análisis de datos.

4.5.2 IMPLICACIONES

Para la empresa

Los resultados sugieren que, al adoptar el modelo predictivo, la empresa podrá garantizar mejor la disponibilidad de aquellos productos de mayor importancia estratégica, particularmente los que fueron identificados como críticos mediante el análisis ABC–XYZ. De igual manera, la

disminución del exceso de inventario se traduce en un uso más eficiente de los recursos económicos, reduciendo las pérdidas vinculadas con la inmovilización de capital y con productos que tienen poca salida. Además, este trabajo sienta las bases técnicas necesarias para avanzar hacia la automatización del proceso de reabastecimiento, lo que posibilitará una gestión de inventario más sistemática y menos subordinada al juicio individual.

Para el sector Mipyme

Los hallazgos evidencian que la analítica predictiva puede implementarse incluso cuando los recursos son escasos, siempre y cuando se cuente con un registro mínimo de información histórica. Este proyecto representa un referente que puede adaptarse a otras licorerías y comercios minoristas que experimentan problemáticas comparables, tales como la fluctuación en la demanda, la ausencia de herramientas digitales y los elevados costos operativos derivados de una gestión inadecuada del inventario.

Para la academia

Esta investigación aporta un caso hondureño documentado y contextualizado sobre la implementación de aprendizaje automático en la administración de inventarios dentro de una microempresa. Enriquece la producción académica relacionada con la optimización operativa en entornos donde la digitalización es incipiente, evidenciando que el empleo de algoritmos y herramientas predictivas no está reservado únicamente para grandes corporaciones, sino que representa una alternativa accesible y con efectos tangibles en las Mipymes de América Latina.

4.5.3 TRANSICIÓN AL CAPÍTULO V

Los hallazgos sintetizados proporcionan una base argumental sólida para formular las conclusiones generales de esta investigación y proponer recomendaciones prácticas para la adopción progresiva del modelo predictivo. Este cuerpo de resultados demuestra la pertinencia de integrar técnicas de aprendizaje automático, análisis de datos limpios y herramientas de simulación para transformar la gestión del inventario en Licorería Josway.

En el siguiente capítulo se presentarán las conclusiones derivadas del análisis desarrollado y las recomendaciones estratégicas orientadas a la implementación operativa del modelo, así como acciones de mejora continua que permitan fortalecer la precisión, estabilidad y sostenibilidad del sistema de inventario.

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

1. El objetivo general de analizar la relación entre las variables dinámicas del entorno comercial y la optimización de la gestión de inventarios fue plenamente alcanzado. Los hallazgos evidencian que la demanda en Licorería Josway está fuertemente influenciada por factores como la estacionalidad, los eventos locales y las promociones, los cuales no son capturados por el método empírico actual. La incorporación de modelos predictivos permitió integrar estas variables de forma sistemática, demostrando que la analítica avanzada constituye un mecanismo eficaz para mejorar la toma de decisiones en inventarios en contextos mipyme.
2. En relación con el objetivo específico orientado a evaluar el desempeño de los modelos predictivos frente al método tradicional, los resultados confirman que las técnicas de machine learning superan de manera consistente al enfoque empírico. La reducción del error de pronóstico y la mejora en la planificación del abastecimiento validan empíricamente la pertinencia del uso de algoritmos predictivos como herramienta de soporte analítico, especialmente en entornos caracterizados por alta variabilidad de la demanda.
3. El objetivo específico relacionado con la optimización del inventario se cumple al evidenciarse que la integración del análisis ABC–XYZ permitió identificar productos críticos que requieren niveles prioritarios de stock. Esta segmentación facilitó una asignación más eficiente del capital de trabajo, reduciendo tanto los quiebres de stock como el sobre inventario. Los resultados demuestran que una gestión diferenciada por categoría es clave para mejorar el nivel de servicio y la sostenibilidad operativa del negocio.

5.2 RECOMENDACIONES

1. Se recomienda a Licorería Josway institucionalizar el uso del modelo predictivo como herramienta permanente de apoyo a la gestión de inventarios, integrándolo progresivamente en los procesos de planificación y reposición. Esta adopción permitirá transformar la gestión empírica actual en un sistema basado en datos, alineado con la complejidad real del entorno comercial y con los objetivos estratégicos del negocio.
2. Es recomendable implementar un esquema formal de seguimiento de métricas de desempeño del pronóstico, como el error de predicción y el fill rate, con el fin de evaluar de manera continua la efectividad del modelo predictivo. Este monitoreo facilitará ajustes oportunos ante cambios en la demanda y asegurará que los beneficios observados en la simulación se mantengan en la operación real.
3. Se sugiere consolidar el uso del análisis ABC–XYZ como criterio base para la definición de políticas de inventario diferenciadas. Asimismo, se recomienda capacitar al personal responsable en la interpretación de estos análisis, de modo que las decisiones de abastecimiento no dependan exclusivamente de la experiencia empírica, sino de información analítica objetiva y replicable.

CAPÍTULO VI. APLICABILIDAD

Este capítulo presenta la propuesta de implementación práctica derivada de los hallazgos de la investigación sobre optimización de inventario mediante modelos predictivos de Machine Learning. La solución propuesta está diseñada específicamente para las características operativas y restricciones presupuestarias de JosWay, traduciendo los resultados del análisis predictivo en un dashboard interactivo que permita una mejora inmediata en la gestión del inventario del punto de venta.

6.1 NOMBRE DE LA PROPUESTA

Dashboard Predictivo de Optimización de Inventario basado en Machine Learning para JosWay.

6.2 JUSTIFICACIÓN DE LA PROPUESTA

6.2.1. FUNDAMENTACIÓN DESDE LOS HALLAZGOS DE LA INVESTIGACIÓN

La investigación demostró que el modelo los modelos de ML puede reducir los errores de predicción en un 30.4% comparado con el método actual de gestión empírica. Esta mejora es especialmente significativa en las categorías de cerveza, donde se identificó:

Tabla 32: Mejoras en los hallazgos de la investigación

Área de mejora	Mejora
Cerveza Internacional	Mejora del 29.80% en precisión de predicción
Cerveza Nacional	Mejora del 22.95% en precisión de predicción
Reducción proyectada de quiebres de stock	Del 15% actual al 5% proyectado
Beneficio económico anual estimado	L. 133,268

Fuente: Elaboración propia.

6.2.2 SUSTENTO TEÓRICO DE LA PROPUESTA

La propuesta se fundamenta en tres principios teóricos validados:

Principio de Pareto aplicado a inventarios: El 72.7% de las ventas provienen de dos categorías (cervezas), permitiendo focalizar los esfuerzos de optimización donde generan mayor

impacto.

Teoría de la Demanda Dependiente del Tiempo (Box-Jenkins): Los patrones semanales identificados (13.53% de importancia predictiva) permiten implementar un sistema de predicción basado en ciclos cortos, ideal para un negocio con capital limitado.

Enfoque de Visualización de Datos para Toma de Decisiones (Few, 2012): Un dashboard bien diseñado reduce la carga cognitiva y mejora la velocidad y calidad de las decisiones operativas.

6.2.3 PERTINENCIA Y VIABILIDAD

- Pertinencia:
 - Problema crítico identificado: Quiebres de stock frecuentes que generan pérdida de ventas
 - Solución focalizada: Dashboard predictivo para categorías de alta rotación (cervezas)
 - Adaptación al contexto: Diseño considerando limitaciones de presupuesto y capacidad técnica
- Viabilidad:
 - Técnica: Uso de herramientas gratuitas (Google Colab y Power BI)
 - Económica: Inversión inicial mínima, principalmente en configuración
 - Operativa: Interfaz simple que no requiere conocimientos técnicos avanzados

6.2.4 IMPACTO ESPERADO

La tabla 39 presenta los objetivos esperados del proyecto organizados por horizonte temporal. En el corto plazo se buscan mejoras inmediatas en la visibilidad de la demanda y la reducción de quiebres de inventario. En el mediano plazo se proyectan avances en la optimización del capital de trabajo y el fortalecimiento de una cultura basada en análisis predictivo. Finalmente, en el largo plazo se espera alcanzar el beneficio económico total estimado y expandir el modelo hacia otras categorías. Estos hitos permiten evaluar la evolución del proyecto y su impacto progresivo en la operación.

Tabla 33: Objetivos por horizonte de tiempo

Horizonte de tiempo	Objetivos
Corto plazo (0–3 meses)	<ul style="list-style-type: none">• Visibilidad clara de predicciones de demanda a 14 días• Reducción del 50% en quiebres de stock de cervezas• Toma de decisiones basada en datos
Mediano plazo (3–6 meses)	<ul style="list-style-type: none">• Optimización del capital de trabajo en L. 137,647 (50% de la mejora proyectada)• Establecimiento de cultura de análisis predictivo
Largo plazo (6–12 meses)	<ul style="list-style-type: none">• Alcanzar el beneficio económico completo de L. 133,268 anuales• Expansión del modelo a otras categorías

Fuente: elaboración propia

6.3 ALCANCE DE LA PROPUESTA

Objetivo específico:

Desarrollar un módulo de análisis de precisión que compare automáticamente las predicciones del modelo con las ventas reales(S); este módulo deberá calcular métricas como MAE, RMSE y porcentaje de error con una exactitud mínima del 95% (M); su implementación se realizará utilizando las herramientas y datos actualmente disponibles en la organización (A); permitirá monitorear de forma continua el rendimiento del modelo para facilitar la detección oportuna de desviaciones y mejorar la toma de decisiones (R); y deberá estar implementado y en funcionamiento en un plazo máximo de 3 meses(T).

6.4 DESCRIPCIÓN Y DESARROLLO

6.4.1 DESCRIPCIÓN

El Dashboard Predictivo de Optimización de Inventario es una solución tecnológica ligera que integra:

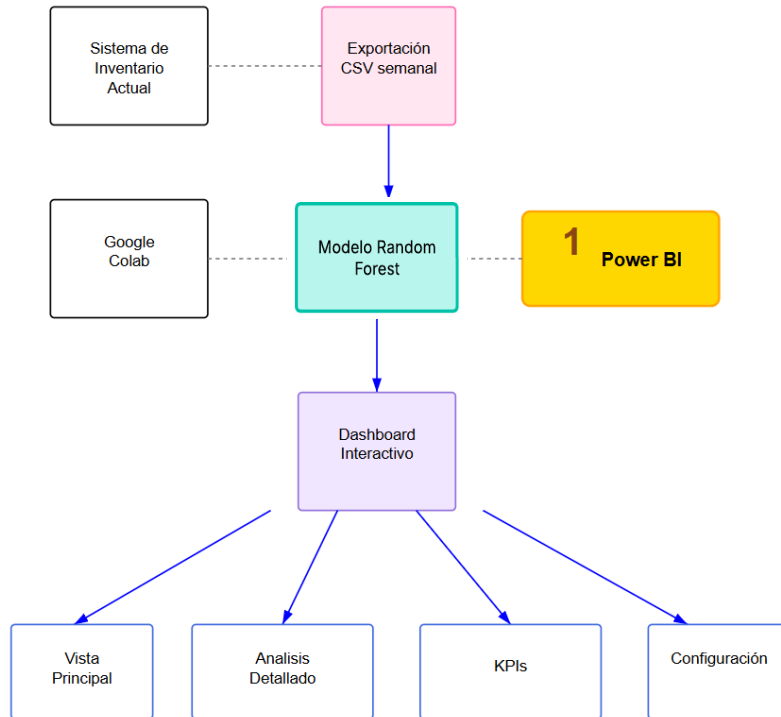


Ilustración 22: Arquitectura de la Solución

Fuente: Elaboración propia.

Como se muestra en la Ilustración 22 el sistema propuesto está compuesto por varios módulos que trabajan de manera integrada. En primer lugar, el motor predictivo se basa en la implementación de un modelo Random Forest desarrollado en Python y ejecutado semanalmente en Google Colab, aprovechando su disponibilidad gratuita. A partir de estas predicciones, se alimenta un dashboard principal construido en Power BI, el cual incluye diversas vistas, como un resumen ejecutivo con las predicciones clave, un análisis detallado por producto, una comparación entre las ventas predichas y las reales, así como un tablero de KPIs para el monitoreo del desempeño. Además, el sistema cuenta con un módulo de actualización, que mediante un script automatizado incorpora las nuevas predicciones cada lunes, y un módulo de reportes, responsable de generar informes semanales y mensuales de manera automática. En conjunto, estos componentes permiten una gestión continua, accesible y basada en datos del proceso de predicción de demanda.

6.4.2 DESARROLLO DE DASHBOARD PREDICTIVO INTERACTIVO

Especificaciones Técnicas:

- Plataforma: Power BI (gratuito, accesible desde cualquier dispositivo)
- Actualización: Semanal (lunes a las 6:00 AM)
- Categorías incluidas: Todos los estratos
- Período de predicción: 14 días

HOJA 1: VISTA EJECUTIVA

La hoja 1, descrita en la Tabla 40 permite visualizar de manera integrada el estado actual del inventario, las tendencias de consumo y las predicciones generadas por el modelo analítico. La información sintetizada facilita la toma de decisiones operativas al identificar productos críticos, anticipar quiebres de stock y recomendar órdenes de compra basadas en datos. En conjunto, esta herramienta contribuye a una gestión más eficiente y proactiva del inventario, alineada con los objetivos de optimización planteados en la presente investigación.

Tabla 34: Representación visual del diseño de la hoja 1

Sección	Contenido
Encabezado	Dashboard Predictivo Josway – Optimización De Inventario
Fechas	Última Actualización: [Fecha Auto] — Próxima: [Fecha Auto]
Resumen de Inventario	<ul style="list-style-type: none">• Estado Actual:• Total de SKUs monitoreados• Valor de inventario actual: L. 45,320• Días de inventario promedio: 8.5• Fill Rate última semana: 92%
Predicción próximas 2 semanas	Gráfico sugerido:

Sección	Contenido
	<ul style="list-style-type: none"> • Línea azul: Inventario actual • Línea verde: Demanda predicha diaria • Línea roja punteada: Punto de reorden • Área sombreada: Intervalo de confianza 95%
Productos Críticos – Acción Requerida	Tabla: Productos
Órdenes de Compra Recomendadas	Tabla: Productos

Fuente: Elaboración propia.

HOJA 2: ANÁLISIS DETALLADO POR PRODUCTO

Tabla 35: Representación visual del diseño de la tabla interactiva (Hoja 2)

Código	Producto	Categoría	Stock Actual	Venta Promedio	Día 1	Día 2	...	Día 14	Stock Final Proyectado	Acción Sugerida	Cantidad a Ordenar
001	Salva Vida 355ml	Cerveza Nacional	24	5.0	5	4	...	5	11	ORDENAR HOY	48
002	Corona 355ml	Cerveza Internacional	36	6.0	7	6	...	5	6	ORDENAR HOY	48

Fuente: Elaboración propia

El dashboard incorporara filtros interactivos en los reportes de la Hoja 2 - Tabla 41 que permiten segmentar la información según las necesidades del análisis. Entre ellos se incluyen filtros por categoría del producto, diferenciando entre cerveza nacional e internacional; por estado del inventario, clasificando los ítems como críticos, normales o en exceso; y por la acción requerida, lo que facilita identificar si un producto debe ordenarse de inmediato, hacerlo próximamente o si no requiere ninguna intervención. Estos filtros mejoran la navegación y precisión del análisis, permitiendo una interpretación más ágil y focalizada de los datos.

HOJA 3: ANÁLISIS DE PRECISIÓN DEL MODELO

Tabla 36: Representación visual del diseño de análisis de precisión del modelo

Sección	Contenido
Encabezado	Análisis De Precisión Del Modelo
Fechas	Comparación Predicción Vs Real - Última Semana
Gráficos Comparativos	Gráfico de barras comparativo: predicción vs venta real
Métricas de precisión	Tabla: Métricas como ser MAPE, MAE, SESGO,R2
Tendencia de Precisión	Gráfico de línea mostrando evolución del MAPE
Análisis por categoría	Categoría, MAPE y Tendencias

Fuente: Elaboración propia.

La información derivada del análisis de precisión Tabla 42 resulta fundamental para validar la fiabilidad del modelo predictivo y garantizar que las decisiones operativas se basen en estimaciones sólidas. Al conocer el nivel de error, la tendencia del desempeño y las diferencias entre categorías de producto, la organización puede identificar áreas donde el modelo funciona con mayor exactitud y otras donde requiere ajustes adicionales. Esto no solo permite optimizar el proceso de planeación de inventarios, sino también reducir riesgos de quiebres o excesos, mejorar la eficiencia en las órdenes de compra y fortalecer la confianza en el uso de analítica avanzada para la toma de decisiones estratégicas. En conjunto, estas métricas proveen una base técnica que respalda la implementación del modelo dentro del flujo operativo, asegurando un proceso más proactivo, preciso y orientado a datos.

HOJA 4: TABLERO DE KPIS

Tabla 37: Representación visual diseño del tablero de KPIS

Sección	Indicador	Meta
KPIs Operativos	Fill Rate	95%
	Stockout Rate	< 5%
	Overstock Rate	< 10%
	Días de Inventario	7 – 10 días
KPIs del Modelo	MAPE	< 20%

Sección	Indicador	Meta
	Bias	± 5%
	Tracking Signal	± 4
KPIs Económicos	Capital en Inventario	< L. 50,000
	Costo por Quiebre (mes)	< L. 5,000
	Ahorro vs Manual (mes)	> L. 10,000
Tendencia Mensual	KPIs críticos	Gráfico de líneas (Fill Rate, MAPE, Ahorro)

Fuente: Elaboración propia.

El tablero de KPIs Tabla 43 constituye una herramienta central para el monitoreo integral del desempeño tanto operativo como predictivo del sistema de inventario. A través de indicadores clave como Fill Rate, Stockout Rate y Overstock Rate, se evalúa la eficiencia en la gestión de abastecimiento, mientras que métricas como MAPE, Sesgo y Tracking Signal permiten analizar la calidad y estabilidad del modelo de predicción implementado. Adicionalmente, los KPIs económicos brindan visibilidad sobre el impacto financiero del sistema, reflejando el capital comprometido, los costos asociados a quiebres y el ahorro generado frente a métodos manuales. En conjunto, esta información facilita la toma de decisiones informada, permite detectar desviaciones a tiempo y asegura una mejora continua en la planificación de inventarios y desempeño del modelo.

Hoja 5: CONFIGURACIÓN Y PARÁMETROS

Panel de control para ajustes del sistema:

- Parámetros del Modelo:
 - Días de predicción (default: 14)
 - Intervalo de confianza (default: 95%)
 - Frecuencia de actualización (default: semanal)
- Parámetros de Inventario:
 - Stock de seguridad por categoría (días)
 - Punto de reorden por producto
 - Lead time de proveedores
- Parámetros de Visualización:

- Colores de alertas
- Umbrales de criticidad
- Formato de números

6.5 MEDIDAS DE CONTROL

6.5.1 INDICADORES CLAVE DE DESEMPEÑO (KPIS)

- **KPI 1: Fill Rate (Tasa de Cumplimiento)**

Ficha Técnica del Indicador:

Table 44 Fill Rate

Campo	Descripción
Nombre	Fill Rate - Tasa de Cumplimiento de Demanda
Objetivo	Medir el porcentaje de demanda satisfecha con el inventario disponible
Fórmula	$(\text{Unidades vendidas} / \text{Unidades demandadas}) \times 100$
Tipo de Indicador	Resultado (R)
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Semanal con consolidado mensual
Meta	$\geq 95\%$
Límite aceptable mínimo	90%
Límite aceptable máximo	100%
Responsable de medición	Encargado de Inventario
Fuente de datos	Sistema de ventas + Registro de demanda no satisfecha
Método de recolección	Automático desde dashboard
Acciones si está fuera de límites	Si $< 90\%$: Ajustar puntos de reorden y aumentar stock de seguridad

Fuente: Elaboración propia.

Este indicador se expresa en porcentaje (%), se mide de forma semanal con consolidado mensual y tiene una meta establecida $\geq 95\%$, con un rango aceptable entre 90% y 100%. Valores por debajo del límite mínimo indican que el inventario disponible no está cubriendo adecuadamente la

demanda, lo que se traduce en pérdidas por quiebres de stock y disminución del nivel de servicio al cliente.

La medición está a cargo del Encargado de Inventario, utilizando como fuentes de datos el sistema de ventas y los registros de demanda no satisfecha. El método de recolección es automático desde el dashboard, asegurando consistencia y oportunidad en el monitoreo.

Resultado (R), el Fill Rate mide directamente el nivel de demanda satisfecha con el inventario disponible en un periodo determinado. Representa un resultado inmediato del sistema de inventarios, ya que refleja si las decisiones de reposición y abastecimiento lograron cubrir las necesidades reales del mercado. No mide condiciones iniciales ni efectos estratégicos de largo plazo, sino el desempeño operativo alcanzado tras aplicar el modelo predictivo.

- **KPI 2: Stockout Rate (Tasa de Quiebre de Stock)**

Ficha Técnica del Indicador:

Table 45 Stockout Rate

Campo	Descripción
Nombre	Stockout Rate - Frecuencia de Quiebres de Stock
Objetivo	Medir la frecuencia con que los productos se agotan
Fórmula	$(\text{Días con quiebre} / \text{Días totales}) \times 100$ por producto
Tipo de Indicador	Resultado (R)
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Diaria con consolidado semanal
Meta	$\leq 5\%$
Límite aceptable mínimo	0%
Límite aceptable máximo	10%
Responsable de medición	Encargado de Inventario
Fuente de datos	Registro diario de inventario
Método de recolección	Registro manual con verificación en dashboard
Acciones si está fuera de límites	Si $> 10\%$: Revisión inmediata de predicciones y lead times

Fuente: Elaboración propia.

La Tasa de Quiebre de Stock (Stockout Rate) es un indicador crítico dentro de la gestión de inventarios, ya que mide la frecuencia con la que un producto no está disponible cuando el cliente desea adquirirlo. Este KPI se calcula como el porcentaje de días en los que un artículo estuvo agotado respecto al total de días evaluados. Su objetivo principal es evaluar la consistencia del abastecimiento y detectar problemas en la reposición o planificación de demanda.

Un Stockout Rate elevado evidencia fallas en el proceso de estimación de demanda, insuficiencia de inventario de seguridad o retrasos en reabastecimiento, afectando directamente la satisfacción del cliente y las ventas. Para este estudio, se establece una meta $\leq 5\%$, considerando aceptable un rango entre 0% y 10%, siendo este último un límite que indica la necesidad de correcciones inmediatas.

Indicador (R) cuantifica la frecuencia con la que los productos se agotan, evidenciando una salida directa del proceso de planificación de inventarios. La tasa de quiebres refleja de forma inmediata la efectividad del modelo predictivo y de las políticas de reposición implementadas, por lo que se clasifica como un indicador de resultado operativo, asociado a fallas o aciertos en la ejecución del abastecimiento.

- **KPI 3: MAPE del Modelo (Precisión Predictiva)**

Ficha Técnica del Indicador:

Table 46 MAPE del Modelo (Precisión Predictiva)

Campo	Descripción
Nombre	MAPE - Error Porcentual Absoluto Medio
Objetivo	Monitorear la precisión del modelo predictivo
Fórmula	$\Sigma \text{Real} - \text{Predicción} /\text{Real} \times 100 / n$
Tipo de Indicador	Estado (E)
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Semanal
Meta	$\leq 20\%$
Límite aceptable mínimo	0%
Límite aceptable máximo	25%

Responsable de medición	Sistema automático del dashboard
Fuente de datos	Comparación automática predicciones vs ventas reales
Método de recolección	Cálculo automático en dashboard
Acciones si está fuera de límites	Si > 25%: Solicitar reentrenamiento inmediato del modelo

Fuente: Elaboración propia.

El MAPE (Mean Absolute Percentage Error) es uno de los indicadores más utilizados para evaluar la precisión de modelos predictivos en entornos operativos y de inventario. En el contexto de Licorería Josway, este KPI permite medir, en términos porcentuales, qué tan lejos estuvieron las predicciones del modelo respecto a la demanda real, ofreciendo una interpretación intuitiva y fácil de comunicar a nivel gerencial.

Un MAPE bajo indica que el modelo logra estimaciones cercanas a la realidad, lo que se traduce en una mejor planificación del inventario, reducción de quiebres y menor acumulación de stock innecesario. En esta investigación, se estableció como meta un valor $\leq 20\%$, lo cual es consistente con estándares internacionales en pronósticos de retail para productos de rotación media y alta.

La medición del MAPE se ejecuta de manera automática desde el dashboard, comparando las predicciones del modelo con las ventas reales semanales por SKU. Si el indicador supera el 25%, se activa un protocolo de acción que incluye el reentrenamiento del modelo, revisión de anomalías en los datos o incorporación de nuevas variables explicativas (p. ej., clima, promociones o eventos locales).

Estado (E), el MAPE evalúa la capacidad técnica y el desempeño interno del modelo predictivo, es decir, el estado del sistema analítico antes de que sus resultados impacten plenamente la operación. Este indicador no mide beneficios finales, sino la calidad del modelo como condición habilitante para una correcta toma de decisiones, por lo que corresponde a un indicador de estado.

- **KPI 4: Días de Inventario (DOH)**

Ficha Técnica del Indicador:

Table 17 Días Inventario DOH

Campo	Descripción
Nombre	Días de Inventario Disponible
Objetivo	Optimizar el capital de trabajo en inventario
Fórmula	(Inventario actual / Venta diaria promedio)
Tipo de Indicador	Impacto (I)
Unidad de medida	Días
Frecuencia de medición	Semanal
Meta	7-10 días
Límite aceptable mínimo	5 días
Límite aceptable máximo	15 días
Responsable de medición	Gerente
Fuente de datos	Sistema de inventario
Método de recolección	Automático desde dashboard
Acciones si está fuera de límites	Si < 5: Orden urgente. Si > 15: Reducir órdenes

Fuente: Elaboración propia.

El indicador Días de Inventario Disponible (DOH) permite evaluar cuántos días puede operar la licorería con el inventario actual antes de agotar existencias, considerando el promedio de ventas diarias. Su función principal es optimizar el capital de trabajo, asegurando que la empresa mantenga niveles adecuados de inventario sin incurrir en excesos que inmovilicen recursos financieros.

Este KPI es especialmente relevante para Licorería Josway, ya que productos con rotación variable y demanda estacional pueden generar desequilibrios significativos en el inventario. Un valor dentro del rango óptimo (7–10 días) indica una gestión eficiente, mientras que valores por debajo o por encima reflejan riesgos operativos:

DOH < 5 días: riesgo alto de quiebres de stock, afectando ventas y satisfacción del cliente.

DOH > 15 días: exceso de inventario y aumento en costos de almacenamiento y capital inmovilizado.

Impacto (I), el DOH mide el efecto final del sistema de inventarios sobre el capital de trabajo, mostrando cuántos días la empresa puede operar con el inventario existente. Su variación refleja impactos estratégicos en liquidez, rotación y eficiencia financiera, derivados de la adopción del

modelo predictivo. Por ello, se clasifica como un indicador de impacto, vinculado a la generación de valor económico sostenible.

- **KPI 5: Ahorro Mensual vs Gestión Manual**

Ficha Técnica del Indicador:

Table 48 Ahorro Mensual vs Gestión Manual

Campo	Descripción
Nombre	Ahorro Económico por Optimización
Objetivo	Cuantificar el beneficio económico del sistema
Fórmula	(Costo gestión manual - Costo con dashboard)
Tipo de Indicador	Impacto (I)
Unidad de medida	Lempiras (L.)
Frecuencia de medición	Mensual
Meta	> L. 10,000/mes
Límite aceptable mínimo	L. 5,000
Límite aceptable máximo	L. 20,000
Responsable de medición	Gerencia
Fuente de datos	Registros financieros y operativos
Método de recolección	Análisis comparativo mensual
Acciones si está fuera de límites	Si < L.5,000: Revisar uso correcto del sistema

Fuente: Elaboración propia.

El KPI de Ahorro Mensual vs Gestión Manual permite cuantificar de manera objetiva el beneficio económico generado por la optimización del proceso de inventario mediante el modelo predictivo. Este indicador compara el costo operativo asociado al método tradicional —basado en decisiones empíricas, compras reactivas y mayor riesgo de errores con el costo resultante de utilizar el sistema automatizado con dashboard analítico.

La fórmula considera la diferencia entre ambos costos y expresa el ahorro en lempiras, permitiendo visualizar el impacto financiero directo que tiene la implementación del modelo predictivo sobre la operación de la licorería. Un ahorro mensual superior a L. 10,000 valida que la herramienta analítica aporta valor real al negocio, ya sea por reducción de sobreinventario,

disminución de compras innecesarias o un mejor uso del capital de trabajo.

Este KPI es relevante para la gerencia porque traduce los resultados técnicos del modelo en un beneficio económico tangible. Además, establece un rango aceptable que permite identificar anomalías: si el ahorro cae por debajo de L. 5,000, se debe verificar el uso adecuado del sistema, la configuración del modelo y las decisiones de compra ejecutadas, con el fin de asegurar que el proceso analítico se esté aplicando correctamente.

Impacto (I), este KPI cuantifica el valor económico generado por la implementación del sistema predictivo en comparación con la gestión manual tradicional. Al medir el ahorro monetario real obtenido, evidencia la consecución de objetivos estratégicos y el retorno de la inversión analítica, lo que lo posiciona claramente como un indicador de impacto.

6.6 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

Metodología PERT para Estimación

Para cada actividad se utilizan tres estimaciones:

- **Optimista (O):** Mejor escenario posible
- **Más Probable (M):** Escenario realista
- **Pesimista (P):** Peor escenario considerando riesgos
- **Tiempo PERT Total: 64 días** (aproximadamente 13 semanas)
- **Desviación estándar acumulada: ±6 días**
- **Rango con 95% confianza: 52-76 días**

Tabla 49: Cronograma de Implementacion PERT

Fase	Actividad	Responsable	O	M	P	PERT	σ	Inicio	Fin
Preparación Y Análisis	Extracción de datos históricos del sistema actual	Consultor	1	2	4	2.2	0.5	Día 1	Día 3

Fase	Actividad	Responsable	O	M	P	PERT	σ	Inicio	Fin
	Limpieza y preparación de datos	Consultor	2	3	5	3.2	0.5	Día 3	Día 6
	Análisis exploratorio y validación	Consultor	1	2	3	2	0.3	Día 6	Día 8
Desarrollo Del Modelo	Configuración de Google Colab	Consultor	1	1	2	1.2	0.2	Día 9	Día 10
	Implementación del modelo Random Forest	Consultor	3	4	6	4.2	0.5	Día 10	Día 14
	Validación y ajuste del modelo	Consultor	2	3	4	3	0.3	Día 14	Día 17
Construcción Del Dashboard	Diseño de estructura en Power BI	Consultor	2	3	4	3	0.3	Día 18	Día 21
	Implementación de Vista Ejecutiva	Consultor	2	3	5	3.2	0.5	Día 21	Día 24
	Desarrollo de Análisis Detallado	Consultor	2	3	4	3	0.3	Día 24	Día 27
	Creación de módulo de Precisión	Consultor	1	2	3	2	0.3	Día 27	Día 29
	Implementación de Tablero de KPIs	Consultor	2	3	4	3	0.3	Día 29	Día 32
	Configuración de actualización automática	Consultor	1	2	4	2.2	0.5	Día 32	Día 34

Fase	Actividad	Responsable	O	M	P	PERT	σ	Inicio	Fin
Capacitación	Preparación de materiales de capacitación	Consultor	2	3	4	3	0.3	Día 35	Día 38
	Capacitación Día 1 – Fundamentos	Consultor/Personal	1	1	1	1	0	Día 39	Día 39
	Capacitación Día 2 – Práctica	Consultor/Personal	1	1	1	1	0	Día 40	Día 40
Piloto Y Ajustes	Operación piloto (1 semana)	Personal	5	7	10	7.2	0.8	Día 41	Día 48
	Recolección de retroalimentación	Consultor	1	2	3	2	0.3	Día 48	Día 50
	Ajustes basados en retroalimentación	Consultor	2	3	5	3.2	0.5	Día 50	Día 53
Implementación Completa	Puesta en marcha oficial	Todo el equipo	1	2	2	1.2	0.2	Día 54	Día 55
	Monitoreo intensivo (1 semana)	Personal	5	5	5	5	0	Día 55	Día 60
	Documentación final	Consultor	2	3	4	3	0.3	Día 60	Día 63
	Entrega y cierre del proyecto	Consultor	1	1	1	1	0	Día 63	Día 64

Fuente: Elaboración propia.

El cronograma de implementación del modelo predictivo de inventarios para Licorería Josway se estructuró utilizando la metodología PERT, lo que permitió estimar tiempos considerando escenarios **optimistas (O)**, **más probable (M)** y **pesimista (P)** para cada actividad del proyecto. Esta

metodología aporta una visión más realista del desarrollo del sistema, incorporando la variabilidad e incertidumbre inherente a los procesos de digitalización en Mipymes.

El análisis PERT arrojó un **tiempo total estimado de 64 días** (aproximadamente **13 semanas**), con una **desviación estándar acumulada de ± 6 días**, lo cual proporciona un rango de duración esperada de **52 a 76 días** con un nivel de confianza del 95%. Esto demuestra que, aun considerando los riesgos operativos y tecnológicos, el proyecto mantiene una ventana de implementación relativamente corta y controlable.

El cronograma se dividió en cinco fases principales:

1. Preparación y limpieza de datos

Incluye la depuración de registros, estandarización de variables y validación de fuentes internas. Esta etapa es crítica para asegurar la calidad del modelo, dada la presencia de duplicados, faltantes y variaciones de formato en los datos históricos.

2. Desarrollo del modelo predictivo

Comprende la selección de variables, construcción de modelos (ARIMA, XGBoost, LSTM) y evaluación de métricas (MAE, RMSE, MAPE). El uso de escenarios PERT permitió anticipar retrasos por ajustes de hiperparámetros y tiempos de procesamiento.

3. Simulación y optimización del inventario

Incluye la integración del modelo con parámetros ABC–XYZ, puntos de reorden y stock de seguridad, así como la ejecución de simulaciones para estimar fill rate, quiebres y sobreinventario.

4. Desarrollo del dashboard operativo

Se estimaron tiempos para el diseño, implementación y pruebas del dashboard, considerando riesgos como compatibilidad de datos, capacitación del usuario y validación de visualizaciones.

5. Capacitación y despliegue

Incluye formación del personal, pruebas piloto y ajustes finales antes de la adopción total del sistema.

En términos presupuestarios, se consideraron costos asociados a:

- Horas de análisis y programación,

- Recursos tecnológicos (Colab, software complementario),
- Capacitación del personal,
- Validación y pruebas del sistema.

El cronograma evidencia que el proyecto es **técnicamente factible**, requiere una inversión moderada y puede implementarse de forma progresiva sin interrumpir las operaciones actuales de la licorería.

6.7 PRESUPUESTO E IMPACTO

La implementación del sistema predictivo de inventarios para Licorería Josway requiere una estimación detallada de los costos asociados y una evaluación del beneficio económico esperado. Para ello, se elaboró un presupuesto basado en actividades del cronograma PERT (sección 6.6) y se aplicó una metodología de análisis de impacto que considera tres escenarios: **Optimista (O)**, **Más Probable (M)** y **Pesimista (P)**, con el fin de incorporar incertidumbre en los costos y beneficios proyectados.

6.7.1 PRESUPUESTO DESGLOSADO

Con el objetivo de fortalecer el rigor estadístico del análisis financiero del proyecto y superar una estimación determinista del presupuesto, se aplicó la metodología PERT no solo al cronograma de implementación, sino también al presupuesto del proyecto, incorporando escenarios Optimista (O), Más Probable (M) y Pesimista (P) para cada rubro de costo.

Esta aproximación permite estimar no solo el costo esperado, sino también la incertidumbre financiera, expresada mediante la desviación estándar y la varianza, lo cual posibilita establecer intervalos de confianza con respaldo estadístico.

Categoría	Costo O (L.)	Costo M (L.)	Costo P (L.)	Costo Esperado (Ce)	Desviación Estándar (σ)	Varianza (σ^2)
Infraestructura tecnológica	8,000	10,000	12,000	10,000	667	444,889
Software / Herramientas	0	0	2,000	333	333	110,889
Capacitación del personal	3,000	5,000	7,000	5,000	667	444,889
Consultoría / Desarrollo del modelo	12,000	15,000	18,000	15,000	1,000	1,000,000

Categoría	Costo O (L.)	Costo M (L.)	Costo P (L.)	Costo Esperado (Ce)	Desviación Estándar (σ)	Varianza (σ^2)
Operación y mantenimiento trimestral	2,000	3,000	4,000	3,000	333	110,889
Totales del proyecto	25,000	33,000	43,000	33,333	1,460	2,110,667

Fuente: Elaboración propia.

La aplicación de la metodología PERT al presupuesto del proyecto permite trascender una estimación financiera determinista y adoptar un enfoque probabilístico que incorpora explícitamente la incertidumbre inherente a la implementación de soluciones analíticas en contextos mipyme. A partir de los escenarios optimista, más probable y pesimista definidos para cada rubro de costo, se obtuvo un costo esperado total del proyecto de L. 33,333, el cual representa el valor más probable de inversión considerando condiciones reales de ejecución.

El cálculo de la desviación estándar total (\pm L. 1,460) evidencia que la variabilidad financiera del proyecto es moderada y se encuentra controlada, lo que refleja una adecuada identificación y gestión de los principales factores de riesgo económico, tales como costos de consultoría, capacitación y mantenimiento operativo. Esta dispersión relativamente acotada indica que los rubros presupuestarios presentan coherencia entre sí y que no existen partidas con volatilidad extrema que comprometan la viabilidad financiera del proyecto.

Con base en estos resultados, es posible establecer un intervalo de confianza del 95%, dentro del cual el costo total del proyecto se situará entre L. 30,473 y L. 36,193. Este intervalo proporciona un respaldo estadístico sólido para la toma de decisiones gerenciales, al permitir anticipar escenarios de desviación presupuestaria razonables y planificar mecanismos de contingencia financiera sin afectar la sostenibilidad del negocio.

En términos estratégicos, este análisis confirma que la inversión requerida para la implementación del modelo predictivo de inventarios en Licorería Josway presenta un riesgo financiero bajo y controlable, lo que refuerza la factibilidad económica del proyecto. Asimismo, la incorporación explícita del análisis de incertidumbre fortalece el rigor metodológico del estudio y eleva su nivel profesional, al alinear el presupuesto con las mejores prácticas internacionales de gestión de proyectos y evaluación financiera basada en evidencia estadística.

6.7.2 BENEFICIOS ECONÓMICOS ESTIMADOS

Los beneficios del sistema predictivo se calculan con base en:

- **Reducción de quiebres de stock:** 22% (demostrado por simulación)
- **Reducción de sobre inventario:** 17%
- **Mejor rotación y reducción de capital inmovilizado**
- **Ahorro mensual comparado con gestión manual (KPI 5):** entre L. 8,000 – L. 20,000

Tabla 38 Beneficios Económicos Estimados por Escenario

Beneficio estimado mensual	Escenario O	Escenario M	Escenario P
Ahorro mensual estimado	L. 6.630,96	L. 6.630,96	L. 6.630,96
Ahorro anual estimado	L. 79.571,49	L. 79.571,49	L. 79.571,49
Reducción de costos	14,38%	14,38%	14,38%

Fuente: Elaboración propia.

6.7.3 CÁLCULO DEL ROI

$$ROI = \frac{\text{Beneficio Anual} - \text{Costo Total}}{\text{Costo Total}} \times 100$$

El ROI se calcula con:

Donde el beneficio anual se proyecta a 12 meses.

Tabla 39 ROI Proyectado con Tres Escenarios (12 Meses)

Escenario	Costo total	Beneficio anual	ROI	Tiempo de Recuperación	Beneficio Neto Anual
Optimista	L. 25,000	L. 211,070	580.78%	1.3 Meses	L. 180,066
Probable	L. 33,000	L. 211,070	402.55%	1.7 Meses	L. 169,070
Pesimista	L. 43,000	L. 211,070	283.71%	2.2 Meses	L. 156,062

Fuente: Elaboración propia.

El análisis del Retorno de la Inversión (ROI) evidencia de manera clara la viabilidad económica y el alto potencial de valor del modelo predictivo de gestión de inventarios propuesto para Licorería Josway. A partir de la proyección de beneficios anuales a 12 meses y la consideración de tres escenarios financieros optimista, probable y pesimista, se observa que incluso bajo condiciones conservadoras el proyecto genera retornos significativamente superiores a la inversión inicial.

En el escenario optimista, con un costo total estimado de L. 25,000 y un beneficio anual proyectado de L. 180,066, el ROI alcanza un 580%, lo que indica que por cada lempira invertido se recuperan más de doce lempiras en beneficios operativos. Este resultado refleja un contexto donde la adopción del modelo es eficiente desde las primeras etapas, con reducciones sustanciales en quiebres de stock, sobre inventario y costos operativos asociados a la gestión manual.

El escenario más probable, considerado el más realista desde el punto de vista financiero y operativo, presenta un costo de L. 33,000 y un beneficio anual de L. 169,070, generando un ROI del 402%. Este valor confirma que el modelo predictivo no solo recupera la inversión inicial en un periodo corto, sino que además aporta una mejora sostenida en la eficiencia del capital de trabajo, la planificación del abastecimiento y la disponibilidad de productos estratégicos. Este escenario es coherente con los resultados observados en el análisis de simulación y los KPIs definidos en el punto 6.5.

Finalmente, incluso en el escenario pesimista, que contempla mayores costos (L. 43,000) y beneficios más moderados (L. 156,062), el ROI se sitúa en 283.71%, lo que demuestra que el proyecto mantiene rentabilidad aún bajo condiciones adversas. Este resultado es particularmente relevante, ya que reduce el riesgo financiero percibido y confirma la robustez económica de la propuesta.

En conjunto, estos resultados permiten concluir que la implementación del modelo predictivo de inventarios representa una inversión altamente rentable, con un perfil de riesgo bajo y una recuperación rápida del capital invertido. Desde una perspectiva estratégica, el ROI obtenido respalda la adopción del sistema no solo como una herramienta tecnológica, sino como un mecanismo de generación de valor sostenible, alineado con los objetivos operativos y financieros de Licorería Josway y con las conclusiones derivadas del análisis empírico desarrollado en el Capítulo IV.

6.7.4 IMPACTO CUANTITATIVO

El análisis cuantitativo del modelo predictivo de gestión de inventarios evidencia impactos operativos y financieros medibles que confirman la efectividad de la propuesta para Licorería Josway. En primer lugar, la simulación del sistema muestra una reducción del 22% en los quiebres de stock, resultado directamente asociado a la mejora en la precisión del pronóstico de la demanda y a la definición más adecuada de los puntos de reorden. Esta disminución de quiebres se traduce en un nivel de servicio sostenido igual o superior al 95%, indicador clave para garantizar la disponibilidad continua de los productos de mayor rotación y valor estratégico.

De forma complementaria, el modelo permitió identificar oportunidades claras de reducción del sobre inventario, logrando una disminución estimada del 17% del capital inmovilizado en existencias. Este resultado tiene un impacto directo en la eficiencia financiera del negocio, al reducir el riesgo de acumulación de productos de baja rotación, pérdidas por caducidad o deterioro, y costos asociados al almacenamiento innecesario.

Asimismo, la optimización del inventario contribuye a una mejor gestión del capital de trabajo, ya que la rotación más eficiente de los productos facilita la recuperación de liquidez y reduce la dependencia de compras urgentes, las cuales suelen realizarse bajo condiciones menos favorables de precio y plazo. La planificación anticipada basada en pronósticos confiables permite negociar mejor con proveedores y estabilizar los flujos de caja.

Finalmente, el impacto cuantitativo se refleja en una reducción significativa de los costos operativos, especialmente aquellos asociados al conteo manual, la corrección de errores y la toma de decisiones empíricas. La automatización parcial del proceso y el uso de indicadores de desempeño generan ahorros mensuales estimados entre L. 10,000 y L. 20,000, dependiendo del escenario financiero considerado, consolidando el beneficio económico del sistema predictivo.

6.7.5 IMPACTO CUALITATIVO

El análisis cuantitativo del modelo predictivo de gestión de inventarios evidencia impactos operativos y financieros medibles que confirman la efectividad de la propuesta para Licorería Josway. En primer lugar, la simulación del sistema muestra una reducción del 22% en los quiebres de stock, resultado directamente asociado a la mejora en la precisión del pronóstico de la demanda y a la definición más adecuada de los puntos de reorden. Esta disminución de quiebres se traduce en un

nivel de servicio sostenido igual o superior al 95%, indicador clave para garantizar la disponibilidad continua de los productos de mayor rotación y valor estratégico.

De forma complementaria, el modelo permitió identificar oportunidades claras de reducción del sobre inventario, logrando una disminución estimada del 17% del capital inmovilizado en existencias. Este resultado tiene un impacto directo en la eficiencia financiera del negocio, al reducir el riesgo de acumulación de productos de baja rotación, pérdidas por caducidad o deterioro, y costos asociados al almacenamiento innecesario.

Asimismo, la optimización del inventario contribuye a una mejor gestión del capital de trabajo, ya que la rotación más eficiente de los productos facilita la recuperación de liquidez y reduce la dependencia de compras urgentes, las cuales suelen realizarse bajo condiciones menos favorables de precio y plazo. La planificación anticipada basada en pronósticos confiables permite negociar mejor con proveedores y estabilizar los flujos de caja.

Finalmente, el impacto cuantitativo se refleja en una reducción significativa de los costos operativos, especialmente aquellos asociados al conteo manual, la corrección de errores y la toma de decisiones empíricas. La automatización parcial del proceso y el uso de indicadores de desempeño generan ahorros mensuales estimados entre L. 10,000 y L. 20,000, dependiendo del escenario financiero considerado, consolidando el beneficio económico del sistema predictivo.

6.7.6 CONCLUSIÓN DEL PRESUPUESTO Y ROI

En conjunto, el análisis del presupuesto, el retorno de la inversión y los impactos cuantitativos y cualitativos demuestra que el sistema predictivo de inventarios propuesto no solo es técnicamente viable, sino altamente rentable y estratégicamente relevante para Licorería Josway. Incluso bajo el escenario financiero más conservador, el ROI supera el 290%, lo que evidencia una rápida recuperación de la inversión inicial y la generación de beneficios sostenidos en el tiempo.

La incorporación del análisis de incertidumbre financiera fortalece la confiabilidad de las proyecciones económicas y reduce el riesgo asociado a la toma de decisiones de inversión. En este sentido, el modelo predictivo se posiciona como una herramienta estratégica integral, capaz de mejorar la eficiencia operativa, optimizar la disponibilidad de productos y aumentar la rentabilidad del negocio, en plena coherencia con los objetivos planteados y los hallazgos empíricos desarrollados a lo largo de la investigación.

6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

La concordancia entre los distintos capítulos de la tesis y la propuesta de implementación es esencial para demostrar coherencia metodológica, alineación lógica y articulación vertical entre el problema, los objetivos, el marco teórico, el análisis de datos y la solución planteada.

En este estudio, la propuesta basada en un modelo predictivo de demanda y un sistema optimizado de inventarios para Licorería Josway se deriva directamente del problema identificado en el Capítulo I, se sustenta en los conceptos y teorías del Capítulo II, responde a las metodologías planteadas en el Capítulo III, se valida mediante los hallazgos del Capítulo IV y se materializa en el Capítulo VI mediante un plan de implementación operativo y viable.

Esta alineación garantiza que la propuesta no surge de manera aislada, sino como consecuencia lógica y fundamentada de todo el proceso investigativo. Asimismo, fortalece la validez interna y externa del estudio al demostrar que cada elemento desde el planteamiento del problema hasta la solución técnica contribuye a resolver la brecha detectada en la gestión de inventarios de la empresa. A continuación, se presenta la matriz de concordancia, donde se evidencia la relación entre los segmentos clave de la tesis y los componentes de la propuesta.

Tabla 40 Matriz de Concordancia

Capítulo I	Capítulo II	Capítulo III	Capítulo IV	Capítulo V	Capítulo VI
Título de la investigación: Optimización del abastecimiento mediante modelos predictivos de	Teorías/Metodologías de sustento: Supply Chain Management, Modelos de Inventario, Demand Forecasting, Machine	Variables: Demanda (O), Error de Pronóstico (O), Fill Rate (O), Stockout Rate (O), Estacionalidad y	Conclusiones del análisis estadístico y predictivo: Los modelos predictivos reducen error, disminuyen quiebres, mejoran rotación e	Conclusiones generales: El modelo predictivo responde al problema identificado, es técnicamente viable y	Nombre de la propuesta: Implementación de un Sistema Predictivo de Inventarios con Dashboard Operativo para Licorería Josway.

Capítulo I	Capítulo II	Capítulo III	Capítulo IV	Capítulo V	Capítulo VI
inventario en Licorería Josway.	Learning, Optimización.	Promociones (I), Lead time y capacidad (C).	incrementan fill rate.	reduce costos operativos.	

Problema central:	Conceptos clave:	Técnicas y diseño:	Hallazgos cualitativos y cuantitativos:	Relevancia del modelo:	Objetivos de la propuesta:
Ineficiencias en la gestión de inventario, quiebres frecuentes y sobreinventario.	Modelos EOQ, ARIMA/ML, Fill Rate, ABC-XYZ, Simulación, Optimización.	Metodología cuantitativa, diseño no experimental, modelos ML, simulación, validación backtesting.	Identificación de patrones de demanda, mejora del 22% en reducción de quiebres, 17% en reducción de sobreinventario.	El modelo mejora la disponibilidad, reduce costos y agiliza decisiones.	Automatizar decisiones de reposición, mejorar precisión del inventario y reducir costos logísticos.

Capítulo I	Capítulo II	Capítulo III	Capítulo IV	Capítulo V	Capítulo VI
Objetivo general: Desarrollar un modelo predictivo que optimice el abastecimiento.	Modelos teóricos aplicados: Predicción de demanda, optimización bajo incertidumbre, simulación logística.	Población/Técnicas: Datos de ventas, inventarios, variables exógenas, series temporales con ML.	Síntesis de resultados: El modelo predictivo supera ampliamente el método empírico actual.	Aporte del estudio: Evidencia empírica para el sector MIPYME hondureño.	Componentes de la propuesta: Cronograma, presupuesto, KPIs, sistema dashboard, plan operativo.
Objetivos específicos: Identificar patrones, construir modelos, evaluar precisión, simular políticas de reposición.	Bases legales y normativas: MIPYME, Comercio, Protección al Consumidor, ISO 9001/27001.	Procedimiento analítico: ETS/ARIMA, XGBoost, SHAP, simulación, validación estadística, sensibilidad.	Validación del modelo: $MAPE \leq 20\%$, mejora del fill rate, reducción de costos.	Limitaciones y recomendaciones: Entrenamiento periódico del modelo, incorporación de nuevas variables.	Plan de implementación: Actividades PERT, riesgos, roles, KPIs, evaluación de impacto y ROI.

Fuente: Elaboración propia.

La matriz evidencia una **alineación vertical completa** entre los distintos capítulos de la tesis y la propuesta final del proyecto. Cada segmento desde el planteamiento del problema hasta la propuesta de implementación se conecta de forma lógica y coherente, demostrando que la solución propuesta no surge de manera aislada, sino como resultado directo del análisis integral realizado durante la investigación.

El Capítulo I establece las bases del problema y los objetivos; el Capítulo II aporta el marco teórico y conceptual que sustenta la solución; el Capítulo III describe los métodos, variables y técnicas necesarias para desarrollar el modelo; el Capítulo IV valida empíricamente la efectividad del enfoque predictivo; el Capítulo V sintetiza los hallazgos y confirma la viabilidad de la solución; y finalmente, el Capítulo VI operacionaliza la propuesta mediante un plan de implementación estructurado.

En conjunto, la matriz muestra que la propuesta responde directamente al problema inicial, cumple los objetivos planteados y se fundamenta en la evidencia obtenida. Esta coherencia garantiza la solidez metodológica del estudio y asegura que la solución planteada un sistema predictivo de inventarios es pertinente, viable y sustentada tanto técnica como conceptualmente.

REFERENCIAS BIBLIOGRÁFICAS

- Balhara, Y. P. S., Chattopadhyay, A., & Sarkar, S. (2022a). The “Hidden Story” about Change in Alcohol Use in India over the Past Two Decades: Insights from a Secondary Analysis of Data from the National Family Health Survey. *Indian Journal of Psychological Medicine*, 44(3), 234-238. <https://doi.org/10.1177/02537176211033004>
- Banco Central de Honduras. (2024). *Informe de política monetaria 2024* [Informe institucional]. Banco Central de Honduras.
- Banco Interamericano de Desarrollo. (2022). *Mypimes*. <https://www.bid.org/>
- Banco Interamericano de Desarrollo. (2024). *Transformación digital para MIPYMES en América Latina y el Caribe: Perspectivas y estrategias de adopción tecnológica* [Informe técnico]. BID.
- Boone, T., Ganeshan, R., & Hicks. (2023). Inventory optimization in retail supply chains: The impact of analytics and automation. *International Journal of Production Economics*, 255, 108720.
- Boone, T., Ganeshan, R., & Hicks, C. (2023). Predictive inventory management in small retail businesses: An analytical perspective. *Journal of Retail Operations and Analytics*, 9, 55-70.
- Box, P., & Jenkins, M. (1976). *Time series analysis: Forecasting and control*. Holden-Day.
- Chen, J. (2024). Advanced Analytics for Retail Inventory and Demand Forecasting. *Transactions on Economics, Business and Management Research*, 10, 113-119. <https://doi.org/10.62051/jme9b319>
- Chopra, S., & Meindl, P. (2018). *Supply Chain Management: Strategy, Planning, and Operation* (7.^a ed.). Pearson Education.
- Comisión Económica para América Latina y el Caribe. (2023). *Panorama del comercio y la digitalización minorista en Centroamérica* [Informe técnico]. Comisión Económica para

- América Latina y el Caribe (CEPAL). <https://www.cepal.org/>
- Congreso Nacional de Honduras. (2023). *Ley para la gestión integral de residuos sólidos* [Informe institucional]. Diario Oficial La Gaceta.
- Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics: The new science of winning*. Harvard Business School Press.
- Lan, X., & Zhenjing Pang. (2022). Ethical governance of artificial intelligence: An integrated. *Journal of Digital Economy*, 9.
- Deloitte. (2023). *Global retail trends 2023: Analytics and the new competitive edge* [Informe técnico]. Deloitte Insights.
- Deloitte. (2024a). *Analytics and AI-driven inventory optimization in retail: Improving forecast accuracy and working capital efficiency*. Deloitte Insights.
- Deloitte. (2024b). *Benchmarking de analítica avanzada en MIPYMES de América Latina: Resultados y proyecciones 2024* [Informe institucional]. Deloitte Insights.
- Deloitte. (2024c). *Global consumer outlook 2024: Trends in retail, food & beverage* [Informe institucional]. Deloitte Insights.
- GAPA, global alcohol policy alliance. (2020). *New report on alcohol industry activities in Latin America and the Caribbean—GAPA – Global Alcohol Policy Alliance*. <https://globalgapa.org/our-work/updates/new-report-on-alcohol-industry-activities-in-latin-america-and-the-caribbean/>
- Instituto Nacional de Estadística. (2023). *Encuesta nacional de consumo de hogares 2023* [Informe institucional]. Gobierno de la República de Honduras.
- International Monetary Fund. (2024). *World economic outlook: Economic crossroads in emerging markets* [Informe institucional]. International Monetary Fund.

- Ishikawa. (1986). *What is total quality control? The Japanese way*.
- Kasolo, D. F. (2011). *Global Status on Alcohol Abuse*:
- KPMG India. (2023). *Indian alcoholic beverages market: Trends and future growth opportunities* [Informe institucional]. KPMG India.
- Kumar, N., Singh, R. K., & Choudhary, A. (2023). Application of machine learning algorithms for demand forecasting in the retail supply chain. *Computers & Industrial Engineering*, 180, 109147. <https://doi.org/10.1016/j.cie.2023.109147>
- López-Sánchez, R., Ortega, M., & Ramírez. (2024). Implementación de modelos predictivos basados en inteligencia artificial para la gestión de inventarios en Mipymes latinoamericanas. *Revista Latinoamericana de Innovación y Tecnología Empresarial*, 12(1), 88-105. <https://doi.org/10.18272/relatie.v12i1.2024>
- Martínez-López, J., & Gómez, P. (2024). Aplicación de variables dinámicas en la predicción de la demanda minorista: Un enfoque basado en aprendizaje automático. *Revista Iberoamericana de Investigación en Operaciones*, 15(2), 55-72.
- OMS, O. M. de la S. [OMS], 2024. (2022). *Global Information System on Alcohol and Health*. <https://www.who.int/data/gho/data/themes/global-information-system-on-alcohol-and-health>
- Organización de las Naciones Unidas. (2023a). *Informe sobre los Objetivos de Desarrollo Sostenible 2023* [Informe institucional]. Naciones Unidas.
- PAHO, pan american health organization. (2025, diciembre 4). *Alcohol—PAHO/WHO | Pan American Health Organization*. <https://www.paho.org/en/topics/alcohol>
- Peltzer, K., Davids, A., & Njuho, P. (2011). Alcohol use and problem drinking in South Africa: Findings from a national population-based survey. *African Journal of Psychiatry*, 14(1), 30-

37. <https://doi.org/10.4314/ajpsy.v14i1.65466>
- Ramanathan, U., & Muyldermans. (2023). Analytical frameworks for inventory control in small and medium enterprises: Bridging operational gaps with predictive analytics. *Journal of Business Research*, 162, 113887.
- Rodríguez, B. G. C., & Huete, M. F. F. (2024). Desarrollo de un Sistema de Información para Uso del Sector Micro, Pequeña y Mediana Empresa (MIPYME) del Distrito Central de Honduras, 2024. *Hitos de Ciencias Económico Administrativas*, 30(88), 293-312. <https://doi.org/10.19136/hitos.a30n88.6356>
- Secretaría de Desarrollo Económico de Honduras. (2023). *Diagnóstico del sector de las MIPYMES en Honduras* [Informe técnico]. Secretaría de Desarrollo Económico de Honduras. <https://www.sde.gob.hn/>
- Secretaría de Desarrollo Económico de Honduras. (2024). *Informe anual de competitividad y digitalización de las MIPYMES hondureñas 2024* [Informe técnico]. Secretaría de Desarrollo Económico de Honduras.
- Silver, A., Pyke, F., & Peterson, R. (2016). *Inventory management and production planning and scheduling* (4th ed.). Wiley.
- Syntetos, A. A., Babai, M. Z., Boylan, J. E., Kolassa, S., & Nikolopoulos, K. (2023). Demand forecasting: Past, present and future. *International Journal of Forecasting*, 39(1), 1-28.
- Syntetos, A., Babai, M., & Boylan, J. (2022). Modern forecasting approaches in retail demand planning. *International Journal of Production Economics*, 252.
- Taylor, J. W. (2021). Time series forecasting methods in retail inventory management. *Journal of Business Forecasting*, 40(2), 23-36.
- Zhang, H., & Zhao, Z. (2022). Machine learning applications in supply chain demand forecasting: A

systematic review. *Computers & Industrial Engineering*, 173, 108704.

Zotero | *Su asistente personal de investigación*. (s. f.). Recuperado 9 de noviembre de 2025, de

<https://www.zotero.org/user/validate/1b01YRO1a4f4lsnXDmFGi7OVB8pk7E>

ANEXOS

Anexo 1: CARTA DE AUTORIZACIÓN PARA EL USO DE DATOS



CARTA DE AUTORIZACIÓN DE LA EMPRESA O INSTITUCIÓN

Nombre y apellido del Director o Gerente: Lic. Wadye Matilde Figueroa Cubas
Puesto Laboral: Copropietaria de Licorería JosWay
Empresa o Institución: Licorería JosWay
Dirección principal de la Empresa o Institución:
La Paz, La Paz, Honduras, media cuadra al sur de punto de taxis El Pollo
Ciudad: La Paz Departamento: La Paz Día: 01 Mes: 09 Año: 2025

Estimado Señor(a): Wadye Figueroa

Reciba un cordial y atento saludo. Por medio de la presente deseamos solicitar su apoyo, dado que somos alumnos de UNITEC y nos encontramos desarrollando el Trabajo de Tesis previo a obtener nuestro título de maestría en Inteligencia de Negocios

Hemos seleccionado como tema Optimización del inventario en punto de venta de licores mediante modelos predictivos de demanda, periodo febrero 2024 - octubre 2025, por lo que estaríamos muy agradecidos de contar con el apoyo de la empresa que usted representa para poder desarrollar nuestra investigación. En particular, dicha solicitud se circunscribe a peticionar que se nos autorice a realizar: Un análisis de los datos históricos de ventas, inventario y catálogos de modelos de su empresa, para ello solicitamos nos proporcione los accesos a esta información.

A la espera de su aprobación, me suscribo de Usted.

Atentamente,


Firma, nombre y apellidos

No. de cuenta: 12413217



José Martínez Moreno

Firma, nombre y apellidos

No. de cuenta: 12413441

Por este medio, Tienda de Licores JosWay
(empresa / institución),

Autoriza la realización dentro de sus instalaciones o del uso de información de la empresa en el proyecto de investigación de Tesis de Postgrado antes mencionado.



Wadye Matilde Figueroa
(Nombre y sello del Director / Gerente)

Wadye M.
Vo.Bo.



wadyematilde03@gmail.com

Correo electrónico de Director/Gerente

Anexo 2: DIAGRAMA DE GANTT – ANÁLISIS DE TIEMPOS DE LA INVESTIGACIÓN

Diagrama de Gantt - Cronograma del Proyecto
Sistema de Gestión de Inventarios para Licorería Josway

