

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

Optimización de la gestión del inventario de producto terminado en una fábrica productora de aderezos y salsas, mediante modelos de aprendizaje automático.

PROYECTO DE TITULACIÓN

Previo la obtención del Título de:

Magister en Ciencias de Datos

Presentado por:

Mauricio Ricardo Ortiz Lascano

Gandhi Francisco Armas Andrade

GUAYAQUIL - ECUADOR

Año: 2025

DEDICATORIA

El presente proyecto se lo dedico a mi abuelo materno, Galo Ulpiano Lascano Guevara, pues fue él quien desde pequeño me enseñó a esforzarme por mis metas y que, por más difícil que puedan ser las circunstancias, uno siempre debe ser fuerte y salir adelante por sus seres queridos.

Mauricio Ricardo Ortiz Lascano

DEDICATORIA

A mi esposa, Claudia Bastos, por su apoyo constante durante el desarrollo de esta tesis, por su comprensión ante las exigencias académicas y por acompañarme con equilibrio y buen criterio en las decisiones tomadas en este proceso.

Gandhi Francisco Armas Andrade

AGRADECIMIENTO

Mis agradecimientos a Dios por permitirme llegar hasta este punto de mi vida y por todo lo que me ha dado a lo largo de la misma.

De la misma forma, mi eterno agradecimiento a todos y cada uno de mis seres queridos que han sido mi razón para esforzarme y quienes me han ayudado en los momentos más difíciles para poder llegar a donde estoy y ser quien soy, todo lo bueno que tengo se lo debo a ellos.

Mauricio Ricardo Ortiz Lascano

AGRADECIMIENTO

A Dios, por la vida, la fortaleza y la claridad necesarias para culminar este trabajo, y por guiar cada etapa de este proceso académico. A mis profesores de la Maestría en Ciencia de Datos, por su rigor, exigencia y disposición para compartir conocimientos y orientar con criterio cada avance de esta investigación, contribuyendo de manera decisiva a mi formación profesional y a la calidad de esta tesis.

Gandhi Francisco Armas Andrade

DECLARACIÓN EXPRESA

Nosotros, Gandhi Francisco Armas Andrade y Mauricio Ricardo Ortiz Lascano, acordamos y reconocemos que: La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá a los autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor de los autores. Los estudiantes deberán procurar en cualquier caso de cesión de sus derechos patrimoniales incluir una cláusula en la cesión que proteja la vigencia de la licencia aquí concedida a la ESPOL.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, secreto empresarial, derechos patrimoniales de autor sobre software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique a los autores que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 27 de enero del 2026.

Gandhi Francisco Armas Andrade

Mauricio Ricardo Ortiz Lascano

COMITÉ EVALUADOR

MSc. Karen Priscila Calva Yaguana
PROFESOR TUTOR

Ph.D. María Isabel Mera Collantes
PROFESOR EVALUADOR

RESUMEN

El presente proyecto aborda el problema de la planificación de inventario en una fábrica de alimentos mediante la predicción de la demanda a corto plazo. El objetivo fue desarrollar un sistema capaz de estimar las ventas de los siguientes quince días para cada producto, con el fin de optimizar los niveles de inventario y mejorar la eficiencia operativa. La propuesta se justifica por la necesidad de reducir costos de almacenamiento, evitar quiebres de stock y fortalecer la toma de decisiones basada en datos.

Para el desarrollo del modelo se utilizaron datos históricos de ventas del año 2024, que incluyeron información de volúmenes vendidos, precios, fechas y características de los productos. Se aplicaron procesos de limpieza, integración y enriquecimiento de datos, y posteriormente se entrenaron tres modelos de predicción: Exponential Moving Average, Multilayer Perceptron y Random Forest. Los experimentos se ejecutaron siguiendo una metodología supervisada y utilizando métricas de error como MAE y RMSE.

Los resultados mostraron que el modelo Random Forest obtuvo el mejor desempeño en todos los segmentos de productos. Por lo tanto, constituye la solución propuesta para el sistema de pronóstico. Se concluye que esta aproximación permite mejorar la planificación de inventario y constituye una herramienta sólida para el soporte de decisiones.

Palabras Clave: Pronóstico de demanda, Random Forest, Inventario, Análisis de datos, Modelos predictivos.

ABSTRACT

This project addresses the problem of inventory planning in a food manufacturing company through short-term demand forecasting. The objective was to develop a system capable of estimating product sales for the next fifteen days to optimize inventory levels and improve operational efficiency. The proposal is justified by the need to reduce storage costs, prevent stockouts, and strengthen data-driven decision-making.

Historical sales data from 2024 were used, including information on quantities sold, prices, dates, and product characteristics. The data underwent cleaning, integration, and feature-enrichment processes, after which three predictive models were trained: Exponential Moving Average, Multilayer Perceptron, and Random Forest. The experiments followed a supervised learning methodology and used error metrics such as MAE and RMSE.

The results showed that the Random Forest model achieved the best performance across all product segments. Therefore, it constitutes the proposed solution for the forecasting system. It is concluded that this approach improves inventory planning and provides a reliable tool for decision support.

Keywords: Demand forecasting, Random Forest, inventory, data analysis, predictive models.

ÍNDICE GENERAL

CAPÍTULO 1.....	1
1. INTRODUCCIÓN.....	1
1.1. Descripción del problema.....	2
1.2. Justificación del problema	3
1.3. Solución propuesta.....	3
1.3.1. <i>Arquitectura general</i>	3
1.3.2. <i>Datasets de entrada</i>	5
1.3.3. <i>Evaluación del desempeño</i>	5
1.3.4. <i>Valor agregado</i>	5
1.4. Objetivos.....	6
1.4.1. <i>Objetivo General:</i>	6
1.4.2. <i>Objetivos Específicos:</i>	6
1.5. Marco teórico.....	7
1.5.1. <i>Gestión de inventario</i>	7
1.5.2. <i>Pronóstico de la demanda</i>	7
1.5.3. <i>Aprendizaje automático en la gestión de inventarios</i>	8
1.5.4. <i>Relevancia para PYMEs alimenticias</i>	9
CAPÍTULO 2.....	11
2. METODOLOGÍA	11
2.1. Enfoque metodológico general.....	11
2.2. Alcance, unidades de análisis y supuestos	13
2.3. Fuentes de datos y gobierno del dato	15
2.4. Preparación de datos e ingeniería de características	17
2.5. Modelado predictivo	18

2.6.	Simulación con backorders y KPIs de negocio (R = 7)	21
2.7.	Despliegue operativo (inferencia y prescripción)	24
2.8.	Riesgos, limitaciones y resumen	26
CAPÍTULO 3.....		29
3.	RESULTADOS Y ANÁLISIS	29
3.1.	Alcance, propósito e hipótesis del capítulo	29
3.2.	Panorama de datos y evidencias base (notebooks + informe interactivo)31	
3.2.1.	<i>Preparación y vista general del dataset</i>	31
3.2.2.	<i>Demanda agregada por año y su rol como denominador de KPIs..</i>	32
3.2.3.	<i>Concentración por SKU (ley ABC) y consecuencias para el análisis</i>	32
3.2.4.	<i>Estacionalidad intra–anual y memoria de corto plazo</i>	33
3.2.5.	<i>Riesgos de quiebre por segmento ABC.....</i>	34
3.2.6.	<i>Conexión directa con los notebooks y con el tablero interactivo ...</i>	35
3.3.	Resultados predictivos (EMA, RF y MLP): prueba y lectura operativa..	36
3.3.1.	<i>Métricas globales en prueba.....</i>	36
3.3.2.	<i>Resultados por segmento (ABC) y lectura por SKU</i>	37
3.3.3.	<i>Implicaciones para la reposición semanal.....</i>	37
3.4.	Traducción operativa en inventarios (política semanal con backlog) ...	37
3.4.1.	<i>Desempeño consolidado por modelo</i>	38
3.4.2.	<i>Resultados por segmento ABC</i>	39
3.4.3.	<i>Implicaciones para la operación.....</i>	39
3.5.	Selección final y recomendaciones de despliegue.....	40
CAPÍTULO 4.....		41
4.	CONCLUSIONES Y RECOMENDACIONES.....	41
4.1.	Conclusiones.....	41

4.1.1.	<i>Importancia del trabajo y síntesis de hallazgos</i>	41
4.1.2.	<i>Fortalezas y debilidades del estudio</i>	42
4.1.3.	<i>Implicaciones académicas y empresariales</i>	43
4.2.	Recomendaciones y trabajos futuros	43
4.2.1.	<i>Estandarización del pronóstico y control MLOps (corto plazo)</i>	43
4.2.2.	<i>Ruta a producción del dashboard y gobierno operativo (corto plazo)</i>	44
4.2.3.	<i>Optimización conjunta inventario–producción y reducción de tiempos (mediano plazo)</i>	44
4.2.4.	<i>Escalamiento a materias primas e indicadores financieros integrales (largo plazo)</i>	44
BIBLIOGRAFÍA		45
APÉNDICES		48

ÍNDICE DE FIGURAS

Fig. 1.1 Diagrama de Colaboración	4
Fig. 2.2 Proceso del desarrollo de la solución planteada	16
Fig. 3.3 Demanda en kg y crecimiento	32
Fig. 3.4 Análisis ABC de la demanda en kg	33
Fig. 3.5 Demanda diaria promedio por mes en kilogramos	34
Fig. 3.6 Autocorrelación de corto plazo (demanda diaria agregada)	34
Fig. 3.7 Dashboard interactivo en Power BI	35

ÍNDICE DE TABLAS

Tabla 1.1 Descripción del conjunto de datos usado	5
Tabla 1.2 Métricas de evaluación de desempeño.....	5
Tabla 1.3 Valor agregado brindado por diferentes modelos y/o técnicas	6
Tabla 2.4 Ventanas de tiempo por cada submuestra	20
Tabla 3.5 Conjuntos de datos usados.....	31
Tabla 3.6 Descripción de la cartera de productos.....	35
Tabla 3.7 Métricas por modelo	36
Tabla 3.8 Desempeño de la empresa en inventario y rentabilidad por modelo	38
Tabla 3.9 Desempeño de la empresa en backorders por modelo	38

CAPÍTULO 1

1. INTRODUCCIÓN

Las pequeñas y medianas empresas (PYMEs) del sector de alimentos y bebidas en Ecuador enfrentan un desafío constante en la gestión de inventarios, marcado por la baja precisión en los pronósticos de demanda, la variabilidad en los tiempos de entrega de proveedores y la inestabilidad de los ciclos productivos. Una gestión deficiente en este ámbito no solo conduce a pérdidas por quiebres de stock y a bajos niveles de rotación, sino que además compromete el flujo de dinero dentro de la organización, aspecto crítico en negocios con márgenes brutos inferiores al 50%. Diversos estudios han señalado que la correcta administración de inventarios es un factor diferenciador en la competitividad de las PYMEs manufactureras, pues se relaciona directamente con su capacidad de adaptación a entornos volátiles y con la satisfacción de sus clientes.

Nuestro caso de estudio es la empresa “El Sazón S.A.”, un fabricante de aderezos y salsas de la ciudad de Guayaquil que, durante el año 2024, registró ventas por \$3.028.520. Su cartera de productos consta de 100 referencias, de las cuales, las 9 más vendidas representaron el 66% del total de las ventas (categoría A); las siguientes 18, el 22% (categoría B); y las restantes 73, apenas el 12% (categoría C). Este patrón de concentración confirma la necesidad de enfoques analíticos que prioricen los productos de mayor impacto en los ingresos.

En este contexto, la literatura reciente sobre analítica avanzada y aprendizaje automático destaca el potencial de modelos predictivos para mejorar la gestión de inventarios, integrando información histórica, variables de mercado y factores externos en pronósticos más confiables. La presente investigación se alinea con estas tendencias, proponiendo un marco de solución que busca reducir la incertidumbre, mejorar la eficiencia operativa y contribuir al fortalecimiento competitivo de las PYMEs del sector alimenticio en Ecuador.

1.1. Descripción del problema

“El Sazón S.A.” es un fabricante de aderezos y salsas de la ciudad de Guayaquil, que comercializa sus productos en el canal moderno e institucional, principalmente en la región costa del Ecuador. Para el año 2024 registró ventas de \$3.028.520 (3.033.700 kg), con costos de venta equivalentes al 46% de sus ingresos e inventarios promedio de productos terminados de \$86.600 al costo. Estos niveles se traducen en una tasa de rotación de 16 veces al año, es decir, un inventario promedio de 23 días.

Además de la rotación, otro aspecto a considerar en la medición del desempeño de la gestión, son los pedidos despachados con atraso debido a discontinuidades en el abastecimiento (backorders), ya que representan fallas en el servicio al cliente, además de sobrecostos logísticos. Se estima que, durante el año 2024, los backorders representaron aproximadamente al 3% del total de las ventas, con un sobrecosto promedio de \$0.25/kg, lo que resulta en un sobrecosto logísticos total de \$22.750 en ese año, sin considerar las pérdidas relacionados por el deterioro de la relación con los clientes.

El sistema actual, basado en promedios históricos y la experiencia del jefe de producción, resulta insuficiente frente a la variabilidad de la demanda, la estacionalidad y las promociones. Esta limitación expone a la empresa a riesgos de sobreinventario (costos de almacenamiento, capital inmovilizado) y subinventario (quiebres de stock y pérdida de ventas). La literatura especializada ha mostrado que la incorporación de algoritmos de aprendizaje automático permite pronósticos más robustos y decisiones de reposición más adaptativas (Ntakolia, Kokkotis, Karlsson, & Moustakidis, 2021; Ünal, Erkayman, & Usanmaz, 2023). Incluso, enfoques híbridos basados en redes neuronales y factores externos han demostrado reducciones significativas en costos y quiebres de inventario (Chen & Fu, 2025; Douaioui, Oucheikh, Benmoussa, & Mabrouki, 2024).

1.2. Justificación del problema

Cabe mencionar que las empresas líderes en este sector industrial rotan sus inventarios de productos terminados a razón de 24 veces al año, mientras que “El Sazón” lo hace tan solo a una tasa de 16 veces al año, lo que refleja una oportunidad sustancial de mejora en eficiencia operativa y uso del capital.

En lo que respecta a los backorders, las mejores empresas del sector tienen niveles de servicio del 99%, es decir que, de cada 100 pedidos, 99 son despachados a tiempo y completos, mientras que “El Sazón” despacha el 3% de su volumen de ventas con atraso, lo que se traduce en una clara desventaja competitiva, que podría dar lugar a pérdidas de representación en su actual nicho mercado, además de dificultades en la incursión de segmentos de mayor exigencia.

1.3. Solución propuesta

La solución al problema de optimización del inventario con una determinada frecuencia de reposición, indistintamente de que se traten de reabastecimientos semanales, quincenales, o mensuales, pasa por la tarea de inferir la demanda total hasta el próximo reabastecimiento, y el cálculo de la cantidad a producir, como la diferencia de dicha predicción, con la posición actual del inventario.

La solución que se plantea a continuación requiere que el usuario especifique el producto que se requiere predecir y la fecha tentativa en la que se dará su próximo reabastecimiento. El resultado que generará es el nivel al que hay llevar el inventario para su optimización.

1.3.1. Arquitectura general

El sistema se estructurará en tres capas:

1. Capa de ingesta: El usuario informa al sistema cuales son los productos que se requieren producir; dicho requerimiento podría darse a través de un cronograma de trabajo preestablecido donde consten fechas tentativas de producción, susceptible

a ajustes emergentes según las necesidades de la demanda, el proceso, o cualquiera de las partes relacionadas.

2. Capa de inferencia / prescripción: El sistema calcula los features con los cuales el modelo fue entrenado, lleva a cabo las inferencias, estima el inventario objetivo como la suma de las predicciones de los días que tienen lugar hasta el próximo reabastecimiento, y finalmente prescribe la cantidad a producir como la diferencia entre la posición actual del inventario y dicho inventario objetivo.
3. Capa de disponibilización y visualización: integración de los resultados en tableros de Power BI y reportes automatizados conectados a la Planificación de Recursos Empresariales (ERP por sus siglas en inglés). De esta forma, las jefaturas de compras y producción contarán con información en tiempo casi real, accesible y accionable, que facilita la toma de decisiones estratégicas y operativas.

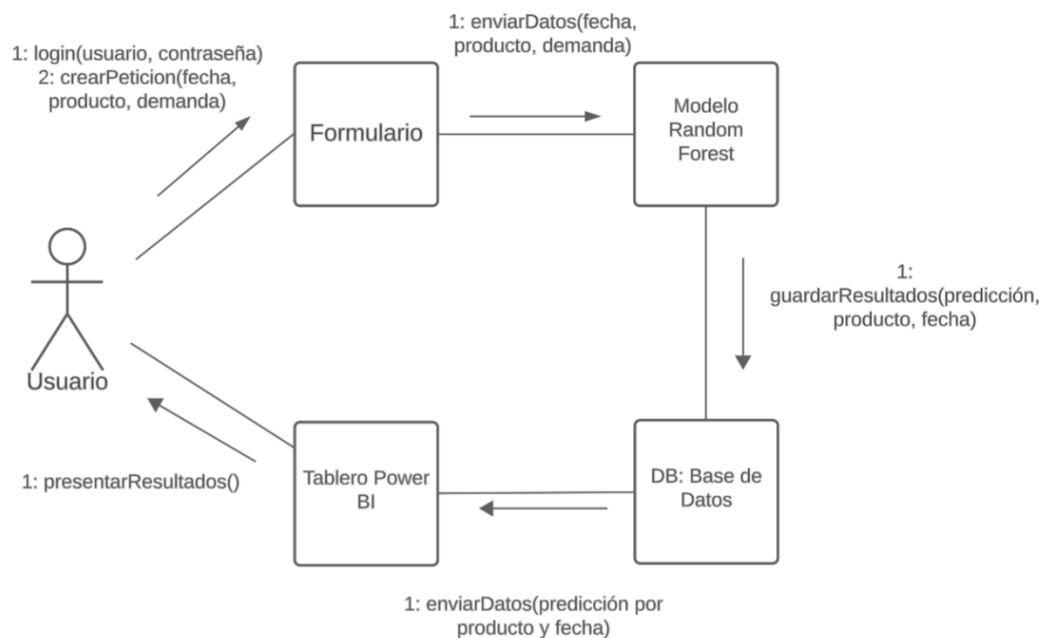


Fig. 1.1 Diagrama de Colaboración

1.3.2. Datasets de entrada

Dada la arquitectura de la solución propuesta, la tarea predictiva consistiría en predicción de la demanda, para lo cual se requeriría de los siguientes datos de entrenamiento:

Tabla 1.1 Descripción del conjunto de datos usado

Concepto	Tipo de dato	Descripción
Fecha	Date	Fecha de la demanda
Demanda en kg	Float	Demanda diaria por SKU medida en kilogramos
Producto	String	Nombre del producto

1.3.3. Evaluación del desempeño

Los modelos serán evaluados mediante métricas como:

Tabla 1.2 Métricas de evaluación de desempeño

Métrica	Descripción	Respaldo en la literatura
MAE (Mean Absolute Error)	Calcula el promedio de las diferencias absolutas entre valores reales y valores predichos. Es ampliamente usado para evaluar la precisión de modelos predictivos.	Willmott & Matsuura (2005) sostienen que el MAE es la medida más natural e inequívoca de la magnitud promedio del error ya que no es ambiguo y representa directamente el error promedio.
RMSE (Root Mean Squared Error)	Penaliza errores grandes más fuertemente que el MAPE. Proporciona una medida robusta del desempeño del modelo.	Fawaz et al. (2019) indican que el RMSE es estándar en evaluación de modelos de series temporales al capturar la magnitud de los errores.
sMAPE	Mide la precisión de los pronósticos, especialmente en el análisis de series temporales, y compara los valores predichos con los valores reales.	Kreinovich, Hung and, Rujira (2014) indican que sMAPE es la principal medida utilizada en las competiciones de pronóstico de series de tiempo.

1.3.4. Valor agregado

La propuesta se alinea con la evidencia empírica reportada en la literatura reciente, diversos estudios demuestran que la incorporación de modelos de aprendizaje automático en la gestión de inventarios se traduce en beneficios financieros y operativos cuantificables, tales como reducciones de costos, mejoras en el nivel de servicio y un

incremento sustancial en indicadores de rentabilidad como el ROI o el GMROI. En la Tabla siguiente se sintetizan algunos resultados destacados:

Tabla 1.3 Valor agregado brindado por diferentes modelos y/o técnicas

Autor / Año	Contexto	Técnica / Modelo	Evidencia Empírica Reportada
Wahedi et al. (2023)	PyME industrial (Dinamarca)	ANN, LSTM, RF, Q-Learning	Reducción de inventario y lead time; mejoras económicas significativas respecto a métodos estadísticos tradicionales.
Babai et al. (2025)	Revisión sistemática SCM	Supervisado, no supervisado y RL	Incrementos >20% en precisión de pronóstico, con impacto directo en reducción de costos y mejora de servicio.
Loyola-Ferrer et al. (2025)	PyME de bebidas (Perú)	ML + Lean 5S	Reducción del ciclo de pedido en 75.98%, mejora del pronóstico en 38.71% y aumento del OTIF en 51.42%.
Ntakolia et al. (2021)	Industria aeronáutica	RF, LGBM, XGB explicables	Predicción de backorders con AUC=0.95; reducción de costos de quiebres y mayor disponibilidad.
Chen & Fu (2025)	Retail de alimentos	Red neuronal híbrida integrada	Reducción de costos de inventario en 21.14% y mejora en políticas de pedido para perecibles.

1.4. Objetivos

1.4.1. Objetivo General:

Desarrollar e implementar modelos de aprendizaje automático que permitan pronosticar la demanda y optimizar la gestión de inventarios en la fábrica de salsas y aderezos “El Sazón S.A.”, con el fin de incrementar la rotación de 16 a 24 veces al año y reducir backorders del 3% al 1% de la demanda.

1.4.2. Objetivos Específicos:

1. Depurar y analizar datos históricos de demanda, identificando patrones y variables que influyen en su comportamiento (feature engineering).

2. Entrenar y seleccionar un modelo predictivo de demanda mediante la evaluación de su desempeño con métricas como MAE, sMAPE y RMSE.
3. Validar el modelo propuesto mediante indicadores claves de desempeño del negocio: índice de rotación (IR), rendimiento bruto sobre la inversión en inventarios (GMROI), y backorders.
4. Diseñar e implementar un dashboard interactivo (prototipo) para visualizar pronósticos y escenarios de inventario, integrando indicadores de desempeño y simulaciones que apoyen la evaluación y discusión de decisiones de compra y producción.

1.5. Marco teórico

1.5.1. Gestión de inventario

La gestión de inventarios es una función crítica dentro de la cadena de suministro, pues permite equilibrar la disponibilidad de productos frente a la variabilidad de la demanda y los costos asociados a mantener existencias. Entre los indicadores más utilizados destacan la rotación de inventario, que mide cuántas veces se renueva el stock en un período, y el GMROI, que relaciona la rentabilidad con el capital invertido en inventarios (Ramanathan, 2006).

Las políticas de reposición clásicas incluyen los modelos de revisión continua (Q) y revisión periódica (P), en los cuales se definen puntos de pedido y cantidades óptimas en función de la demanda esperada y el tiempo de reposición (Silver, Pyke, & Thomas, 2016). No obstante, estas metodologías se basan en supuestos de demanda estable y lead times constantes, lo cual limita su aplicabilidad en entornos con alta incertidumbre, como el alimenticio.

1.5.2. Pronóstico de la demanda

El pronóstico de la demanda constituye el insumo fundamental para definir políticas de inventario. Tradicionalmente, se han empleado métodos de series temporales como

medias móviles, suavizamiento exponencial y modelos ARIMA (Box, Jenkins, Reinsel, & Ljung, 2016). Estos enfoques tienen la ventaja de ser simples e interpretables, pero su capacidad predictiva disminuye cuando existen múltiples factores externos que afectan la demanda, tales como promociones, estacionalidad irregular o cambios en patrones de consumo.

En respuesta a estas limitaciones, el aprendizaje automático ha ganado relevancia en la última década. Modelos como árboles de decisión, Random Forest y XGBoost, permiten capturar relaciones no lineales entre la demanda y variables explicativas (Panda & Mohanty, 2023).

1.5.3. Aprendizaje automático en la gestión de inventarios

El aprendizaje automático (Machine Learning, ML) es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos capaces de aprender patrones y relaciones a partir de datos históricos, con el objetivo de realizar predicciones o recomendaciones sin necesidad de ser programados explícitamente (Mohamed, Loubna, & Abdelaziz, 2022). En lugar de depender exclusivamente de reglas predefinidas, los modelos de ML ajustan sus parámetros de manera iterativa con base en la experiencia contenida en los datos.

En la literatura se reconocen tres grandes categorías de aprendizaje automático (Ünal, ErKayman, & Usanmaz, 2023):

- Aprendizaje supervisado: el modelo se entrena con datos históricos que incluyen tanto variables predictoras como una variable objetivo. Este tipo es el más común en problemas de pronóstico de demanda e inventarios, donde se dispone de registros de ventas pasadas y características asociadas.
- Aprendizaje no supervisado: busca identificar patrones ocultos o estructuras subyacentes en los datos sin necesidad de etiquetas. Se emplea, por ejemplo, en segmentación de clientes o clasificación de productos según su comportamiento de demanda.

- Aprendizaje por refuerzo: el modelo aprende a tomar decisiones mediante un proceso de interacción con el entorno, recibiendo recompensas o penalizaciones. Se ha aplicado en problemas complejos de planificación y control en tiempo real.

Para el presente trabajo se ha seleccionado un algoritmo de aprendizaje supervisado para series temporales, dado que el problema central es el pronóstico de la demanda y la optimización de políticas de inventario:

- Random Forest: algoritmo de ensamble robusto frente a la variabilidad, capace de integrar factores externos (promociones, lead times, costos), proporcionando interpretabilidad y alto desempeño predictivo (Ntakolia, Kokkotis, Karlsson, & Moustakidis, 2021).

La elección de este algoritmo se justifica porque responde a las características del problema de “El Sazón S.A.”:

- Requiere capturar patrones de demanda no lineales y variables externas.
- Necesita manejo de series de tiempo con estacionalidad y tendencia.
- Exige decisiones óptimas de inventario bajo limitaciones de capacidad y tiempo de reposición.

1.5.4. Relevancia para PYMEs alimenticias

En Ecuador y otros países de Latinoamérica, la adopción de soluciones basadas en inteligencia artificial (IA) y aprendizaje automático (ML) por parte de PYMEs aún está en etapas tempranas, pero existen estudios recientes que ilustran su relevancia y potencial impacto.

En un estudio realizado en la ciudad de Machala, Ecuador, se encontró que el 45% de las pequeñas empresas ya ha implementado IA en procesos como automatización, gestión de inventarios y atención al cliente, lo que evidencia una tendencia creciente hacia la adopción tecnológica comercial en el contexto local (Espinoza & Guamán, 2023).

A nivel regional, en Perú se ha desarrollado un modelo de ML para predecir importaciones de productos agrícolas mediante algoritmos LSTM y Prophet, demostrando la viabilidad de modelos de demanda incluso en sectores agroalimentarios (Huamán et al., 2023).

Aunque no se trata exclusivamente de PYMEs alimenticias, a nivel latinoamericano, se ha identificado que el uso de IA en comercio e industria, incluida la gestión de inventarios, aporta mejoras en eficiencia operativa y reducción de costos, aunque aún enfrenta barreras como limitaciones de inversión y falta de formación técnica (Ramos & Martínez, 2022).

En conjunto, estas evidencias subrayan que, si bien la adopción de ML en inventarios aún es incipiente en PYMEs alimenticias ecuatorianas y latinoamericanas, ya existen experiencias en el país y la región que apuntan al valor tangible y técnico de estas tecnologías. Esto refuerza la aplicabilidad y el impacto potencial de aplicar un sistema predictivo–prescriptivo como el propuesto en esta tesis para “El Sazón S.A.”.

CAPÍTULO 2

2. METODOLOGÍA

2.1. Enfoque metodológico general

El proyecto desarrolla un pipeline de decisión que integra pronóstico diario de demanda por Unidad de Mantenimiento de Existencias (SKU por sus siglas en inglés) con simulación de inventarios que acepta backorders y una capa de despliegue operativo. La única fuente transaccional real es la demanda histórica diaria (Fecha, Producto, Demanda_kg). Se entrenan tres rutas: Media Móvil Exponencial (EMA, línea base), Random Forest (RF) y Perceptrón Multicapa (MLP), bajo entrenamiento offline con validación temporal y sin recursividad (Hyndman & Athanasopoulos, 2018; Breiman, 2001; Goodfellow, Bengio & Courville, 2016).

Se denomina entrenamiento “offline” porque el modelo se ajusta por lotes usando únicamente datos históricos ya observados, fuera del sistema operativo. En esta fase se construyen las features con información hasta el día t (sin fuga), se divide el histórico en cortes temporales para validar (backtesting), y se fijan los hiperparámetros y pesos del modelo. El modelo resultante no aprende “en vivo” durante la operación: en producción solo infiere (predice). Si se detecta degradación o deriva, se ejecuta un nuevo ciclo offline de reentrenamiento con el histórico más reciente y, luego, se vuelve a desplegar.

La ingeniería de características se realiza estrictamente con información $\leq t$: retardos lag_1, lag_7; medias rmean_7, rmean_28; suavizado exponencial ewm_14; calendario (anio, mes, semana, dia_semana, dia_mes) y el identificador estable de producto prod_id. Este diseño conserva la granularidad diaria aun cuando la política de reabastecimiento evaluada es semanal ($R = 7$), lo que brinda flexibilidad operativa futura.

La simulación para selección de modelo se ejecuta en una Expresión de Análisis de Datos (DAX, lenguaje de modelado en Power BI) con la demanda real y con dos insumos

no transaccionales: inventario inicial por SKU y día de producción planificado (restricción operativa). Para cada modelo $m \in \{EMA, RF, MLP\}$ se calcula la cobertura objetivo semanal denotada por $Target_t^{(m)}$:

$$Target_t^{(m)}(7) = \sum_{h=1}^7 \hat{y}_{t+h}^{(m)}, \quad (2.1)$$

y, en el día habilitado, se prescribe el lote a producir para cubrir la demanda de los próximos siete días ($Q_t^{(m)}$):

$$Q_t^{(m)} = \max \{0, Target_t^{(m)}(7) - I_{t-1}\}. \quad (2.2)$$

La dinámica de inventario acepta backorders y se fórmula contra la demanda real y_t :

$$I_t = I_{t-1} + Q_t^{(m)} - y_t, \quad (2.3)$$

con $OnHand_t = \max(I_t, 0)$, $BO_stock_t = \max(-I_t, 0)$ y backorder nuevo BO_new_t definido tras priorizar el despacho del backlog previo con la producción del día. Los Indicadores Clave de Desempeño (KPI) del negocio para comparar modelos son: Días de Inventario promedio (DI, base de consumo suavizada), Backorders (BO) absolutos en kg y relativo a las ventas efectivas, Rotación anual y Margen Bruto del Retorno de la Inversión en Inventario (GMROI) anual; la regla de decisión privilegia menor DI y menor BO% junto con mayor Rotación y mayor GMROI (Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014; Levy, Weitz & Grewal, 2019).

Finalmente, el despliegue operativo mantiene la granularidad diaria y aplica recursividad solo en la inferencia: para cubrir $H \geq 7$, ciertos lags y medias se recalculan con predicciones intermedias \hat{y} y se actualizan diariamente con y_{t+1} para acotar el error acumulado. Con ello, el sistema transforma pronósticos diarios en decisiones prescriptivas ($Target_t(7), Q_t$) coherentes con el plan de producción y con los criterios

económico–operativos que guiaron la selección del modelo (Hyndman & Athanasopoulos, 2018; Silver et al., 1998).

2.2. Alcance, unidades de análisis y supuestos

El estudio abarca la construcción y evaluación de un sistema de apoyo a reposición semanal ($R = 7$) en una fábrica de aderezos y salsas, a partir de pronósticos diarios por SKU y una simulación de inventarios con backorders aceptados. El dataset consiste en registros de demanda diaria con estructura (Fecha, Producto, Demanda_kg). El periodo de análisis se define como $t \in \mathcal{T}$ (días consecutivos) y el portafolio como $i \in \mathcal{S}$ (SKUs). Para cada (i, t) se observa $y_{i,t}$ y se generan pronósticos $\hat{y}_{i,t+h}^{(m)}$ con tres rutas: EMA (línea base), Random Forest (RF) y Perceptrón Multicapa (MLP) (Hyndman & Athanasopoulos, 2018; Breiman, 2001; Goodfellow, Bengio & Courville, 2016).

La unidad de análisis es el par (i, t) . El inventario neto al cierre es $I_{i,t}$ (puede ser negativo), y la producción del día es $Q_{i,t}$, restringida al día planificado de elaboración por SKU. La política evaluada dimensiona un objetivo de cobertura semanal con base en pronósticos diarios y prescribe el lote cuando corresponde:

$$\text{Target}_{i,t}^{(m)}(7) = \sum_{h=1}^7 \hat{y}_{i,t+h}^{(m)}, \quad Q_{i,t}^{(m)} = \max \{0, \text{Target}_{i,t}^{(m)}(7) - I_{i,t-1}\}. \quad (2.4)$$

La dinámica de inventario se fórmula contra la demanda real y permite faltantes:

$$I_{i,t} = I_{i,t-1} + Q_{i,t}^{(m)} - y_{i,t}, \quad (2.5)$$

de modo que $\text{OnHand}_{i,t} = \max(I_{i,t}, 0)$ y $\text{BO_stock}_{i,t} = \max(-I_{i,t}, 0)$. La atención del día prioriza la cartera atrasada con la producción: el backorder nuevo (incremental) se define como:

$$BO_new_{i,t} = \max \{0, y_{i,t} - (OnHand_{i,t-1} + Q_{i,t}^{(m)} - \min [Q_{i,t}^{(m)}, BO_stock_{i,t-1}])\} \quad (2.6)$$

y la contabilidad del backlog cumple:

$$BO_stock_{i,t} = BO_stock_{i,t-1} - \min\{Q_{i,t}^{(m)}, BO_stock_{i,t-1}\} + BO_new_{i,t} \quad (2.7)$$

(Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014).

El alcance de datos se limita deliberadamente a la demanda y a dos insumos operativos no transaccionales para la simulación y prescripción: (i) inventario inicial por SKU al inicio del horizonte y (ii) calendario de producción (día de la semana habilitado). Ventas, producción observada e inventarios históricos no se emplean; sus trayectorias se simulan para comparar rutas predictivas bajo un criterio económico-operativo homogéneo.

Las características predictoras efectivamente utilizadas en los notebooks, todas construidas sin fuga, son: autorregresivos lag_1 y lag_7; promedios rmean_7, rmean_28; suavizado exponencial ewm_14; calendario (año, mes, semana, día_semana, día_mes); e identificador estable prod_id. El entrenamiento es offline con validación temporal; la recursividad solo aparece en inferencia para cubrir $H \geq 7$, recalculando lags y medias con predicciones intermedias y corrigiendo diariamente al observar $y_{i,t+1}$ (Hyndman & Athanasopoulos, 2018).

Las métricas de decisión se calculan sobre las trayectorias simuladas $\{I_{i,t}, OnHand_{i,t}, BO_stock_{i,t}, BO_new_{i,t}\}$: Días de Inventario promedio (base de consumo suavizada), Backorders absolutos en kg y relativo a las ventas efectivas, Rotación anual y GMROI anual. La selección del modelo prioriza menor DI y menor BO%, junto con mayor Rotación y mayor GMROI (Levy, Weitz & Grewal, 2019).

Los supuestos clave son: inventario inicial conocido al inicio; día planificado por SKU constante durante el experimento; aceptación de backorders con prioridad de despacho a la cartera acumulada; y parámetros económicos (precio y costo por SKU) disponibles

cuando se estime GMROI. Bajo estas condiciones, el alcance mantiene consistencia metodológica entre el desempeño predictivo y su impacto operativo, a la vez que respeta las mejores prácticas de series de tiempo y de control de inventarios con faltantes (Hyndman & Athanasopoulos, 2018; Silver et al., 1998).

2.3. Fuentes de datos y gobierno del dato

La investigación se apoya en una única fuente transaccional real: la demanda histórica diaria por SKU, estructurada como (Fecha, Producto, Demanda_kg). Sobre esta tabla se construyen todas las transformaciones para el aprendizaje y la simulación. Además, se emplean dos insumos no transaccionales exclusivamente para la capa operativa: (i) inventario inicial por SKU al inicio del periodo y (ii) plan de producción (día de la semana habilitado por SKU). Estos insumos no forman parte del set de entrenamiento ni de la generación de features; su rol es restringir la prescripción de Q_t en la simulación y en el despliegue.

Desde gobierno del dato, se definieron convenciones y controles para calidad, trazabilidad y no-fuga. El diccionario de datos especifica: Fecha (tipo fecha calendario ISO, zona horaria local), Producto (cadena normalizada que mapea a un maestro de SKU) y Demanda_kg (numérico no negativo). En los notebooks se genera un identificador estable `prod_id` (códigos categóricos enteros) y una tabla de correspondencia (Producto, `prod_id`) para asegurar reproducibilidad en entrenamiento, validación e inferencia. El linaje queda documentado como: Demanda diaria → 01_feature_engineering (construcción de `lag_1`, `lag_7`, `rmean_7`, `rmean_28`, `ewm_14`, variables de calendario `anio`, `mes`, `semana`, `dia_semana`, `dia_mes`, y `prod_id`) → 02_model_training_* (EMA/RF/MLP con validación temporal) → modelo DAX (simulación con backorders, $R = 7$) → tablero (KPIs: Días de Inventario, Backorders kg y % sobre ventas, Rotación anual, GMROI anual).

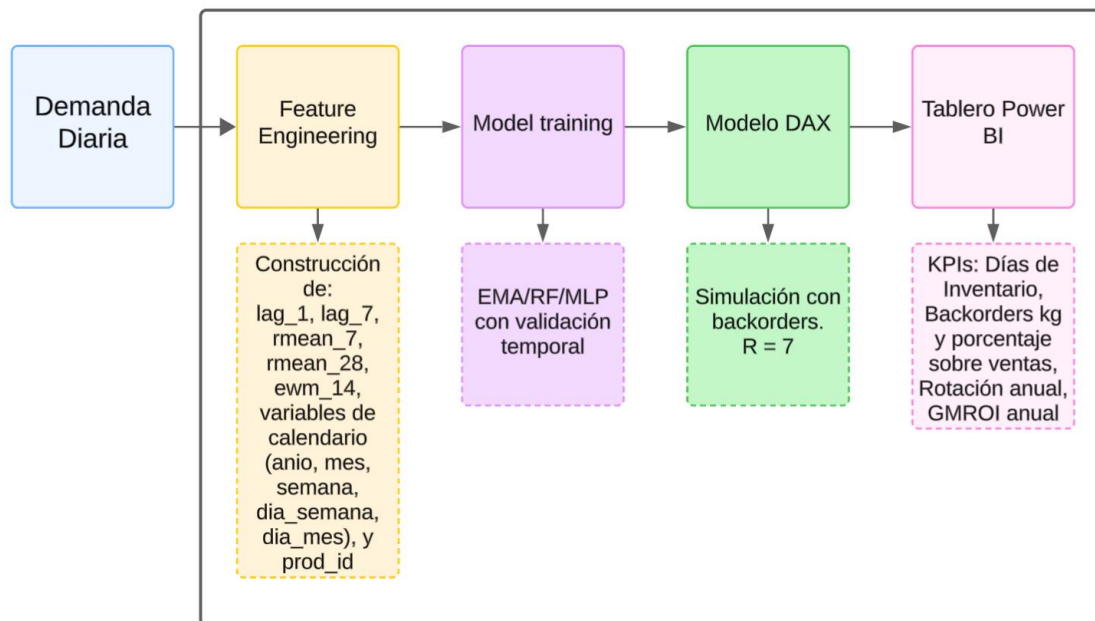


Fig. 2.2 Proceso del desarrollo de la solución planteada

Los controles de calidad se realizaron antes de la ingeniería de características: (a) integridad (completitud por columna y por SKU; umbrales operativos $\geq 98\%$); (b) consistencia (unicidad de pares (Fecha, Producto), claves del maestro de SKU y estabilidad de prod_id); y (c) plausibilidad (detección de atípicos por rango intercuartílico y *winsorización* conservadora cuando el patrón es esporádico). Los faltantes puntuales se imputaron sin prospección (interpolación local o medias retrospectivas) únicamente si los huecos eran cortos; de lo contrario, se preservaron y se excluyeron de ventanas que podrían inducir fuga. Para garantizar no-fuga, todas las transformaciones en el día t se calcularon con información $\leq t$; el uso de valores pronosticados para recalculer lags/medias se restringe a la inferencia en producción, nunca al entrenamiento (Hyndman & Athanasopoulos, 2018).

La seguridad y minimización se abordaron limitando el alcance a datos estrictamente necesarios para el objetivo (demanda y llaves de producto), manteniendo los insumos operativos (inventario inicial y plan de producción) en tablas separadas con control de acceso y versión. El versionamiento de *scripts/notebooks*, semillas deterministas (RF/MLP), parámetros de entrenamiento y exportación de \hat{y}_{t+h} diarios garantizan

trazabilidad y reproducibilidad de extremo a extremo (Kimball & Ross, 2013). Este andamiaje de gobierno proporciona una base coherente con las mejores prácticas de series de tiempo y de control de inventarios con faltantes aceptados (Hyndman & Athanasopoulos, 2018; Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014).

2.4. Preparación de datos e ingeniería de características

La preparación del conjunto de datos se realizó con granularidad **diaria** a nivel de SKU, a partir de la tabla (Fecha, Producto, Demanda_kg). El resultado es un panel $\{y_{i,t}, X_{i,t}\}$ por producto i y día t , donde $y_{i,t}$ es la demanda diaria y $X_{i,t}$ el vector de predictores construidos **sin fuga de información** (todas las transformaciones en t usan únicamente datos $\leq t$). En línea con las mejores prácticas para series temporales, se emplearon ventanas estrictamente retrospectivas y convenciones de calendario ISO (Hyndman & Athanasopoulos, 2018).

El esquema de features efectivamente utilizado en los cuadernos de trabajo se compone de: (i) autorregresivos lag_1 y lag_7 ; (ii) promedios móviles regulares $rmean_7$ y $rmean_28$; (iii) promedio móvil exponencial ewm_14 ; (iv) calendario año, mes, semana, día_semana, día_mes; y (v) identificador estable de producto $prod_id$. Formalmente,

$$lag_1_{i,t} = y_{i,t-1}, lag_7_{i,t} = y_{i,t-7}, \quad (2.8)$$

$$mean_k_{i,t} = \frac{1}{K} \sum_{k=1}^K y_{i,t-k}, k \in \{7, 28\}, \quad (2.9)$$

$$ewm_{14_{i,t}} = \alpha y_{i,t-1} + (1 - \alpha) ewm_{14_{i,t-1}}, \quad \alpha = \frac{2}{14 + 1}. \quad (2.10)$$

Las variables de calendario se obtienen por descomposición determinista de la fecha (semana ISO; lunes = 1). El $prod_id$ se construye mediante codificación categórica determinista φ : Producto $\mapsto \mathbb{N}$ y se mantiene estable entre entrenamiento, validación e

inferencia mediante una tabla de correspondencia única (Producto, `prod_id`). Con ello, el vector final queda:

$$x_{i,t} = (\text{lag}_1, \text{lag}_7, \text{rmean}_7, \text{rmean}_{28}, \text{ewm}_{14}, \text{anio}, \text{mes}, \text{semana}, \text{dia_semana}, \text{dia_mes}, \text{prod_id})_{i,t} \quad (2.11)$$

Previo a la generación de features se aplicaron controles de integridad (completitud por SKU y día), consistencia (unicidad del par Fecha \times Producto y estabilidad de claves) y plausibilidad (detección de atípicos por rango intercuartílico con *winsorización* conservadora cuando correspondía). Los faltantes puntuales se imputaron sin prospección (interpolación local y/o medias retrospectivas) únicamente si los huecos eran cortos; de lo contrario, se preservaron y se excluyeron de las ventanas para evitar sesgos. Finalmente, todas las ventanas que alimentan `rmean_7`, `rmean_28` y `ewm_14` se calcularon con datos observados; solo en despliegue (no en entrenamiento) algunas de estas cantidades podrán re-evaluarse con predicciones intermedias para cubrir un horizonte $H \geq 7$, corrigiéndose diariamente al observar $y_{i,t+1}$ (Hyndman & Athanasopoulos, 2018).

2.5. Modelado predictivo

El modelado se realizó en granularidad diaria y con entrenamiento offline, utilizando como variable objetivo $y_{i,t}$ (`Demanda_kg`) y el vector de predictores definido en 2.4. Se evaluaron tres rutas: una línea base estadística de suavizado exponencial (EMA) y dos modelos de aprendizaje automático, Random Forest (RF) y Perceptrón Multicapa (MLP), entrenados con datos observados, sin recursividad en esta etapa (Hyndman & Athanasopoulos, 2018; Breiman, 2001; Goodfellow, Bengio & Courville, 2016).

Especificación de entrada. Para cada par (i, t) , el conjunto de entrada $X_{i,t}$ incluye `lag_1`, `lag_7`, `rmean_7`, `rmean_28`, `ewm_14`, `anio`, `mes`, `semana`, `dia_semana`, `dia_mes` y el identificador estable `prod_id`. En la práctica, se trabajó en un esquema *pooled* (modelo único para el portafolio) donde `prod_id` permite a los algoritmos distinguir heterogeneidad entre SKUs, manteniendo una sola arquitectura y conjunto de hiperparámetros por ruta.

Ruta EMA (línea base). Se implementó un suavizado exponencial simple de un paso (pronóstico al día siguiente), cuya forma recursiva puede expresarse como:

$$\hat{y}_{i,t+1}^{(EMA)} = \alpha y_{i,t} + (1 - \alpha) \hat{y}_{i,t}^{(EMA)}, \quad \alpha \in (0, 1), \quad (2.12)$$

inicializado con una media histórica del SKU. El parámetro α se ajustó por búsqueda en rejilla sobre un conjunto de validación temporal minimizando el error promedio fuera de muestra.

Ruta RF. El modelo RF estima $f_{RF}(X_{i,t}) \approx y_{i,t}$ como promedio de árboles de regresión entrenados con bootstrapping y selección aleatoria de predictores por división. La robustez a no linealidades y a interacciones entre features lo hace adecuado para capturar patrones calendario y señales suavizadas sin supuestos paramétricos estrictos (Breiman, 2001). Los hiperparámetros clave (número de árboles, profundidad, min samples per leaf, número de predictores por división) se ajustaron por validación temporal, controlando sobreajuste mediante profundidad máxima y tamaño mínimo de hoja.

Ruta MLP. El MLP aproxima $f_{MLP}(X_{i,t}; \theta)$ mediante una red densa con funciones de activación no lineales y regularización (p. ej., early stopping, weight decay). Se usaron capas ocultas de tamaño moderado para favorecer la generalización en presencia de señales suaves (rmean/ewm) y *features* discretas de calendario; la selección de arquitectura y tasa de aprendizaje se realizó con validación temporal, con semillas deterministas para reproducibilidad (Goodfellow et al., 2016).

Esquema de validación temporal. Se empleó backtesting con cortes cronológicos que respetan causalidad. Sea $\mathcal{T} = \{t_0, \dots, t_{\max}\}$; se definieron ventanas de entrenamiento $[t_0, \dots, t_k]$ y validación $[t_{k+1}, \dots, t_{k+h}]$, que se desplazan hacia adelante en varios *folds* (*submuestras*). En cada fold se entrenó con observaciones reales y se evaluó el error

diario por SKU, evitando cualquier recálculo con información futura. A modo ilustrativo, con datos diarios del 1-ene-2023 al 31-may-2024, se usaron cuatro cortes así:

Tabla 2.4 Ventanas de tiempo por cada submuestra

Fold	Ventana de entrenamiento (observado)	Ventana de validación (observado)
1	01-ene-2023 – 30-sep-2023	01-oct-2023 – 30-nov-2023
2	01-ene-2023 – 30-nov-2023	01-dic-2023 – 31-ene-2024
3	01-ene-2023 – 31-ene-2024	01-feb-2024 – 31-mar-2024
4	01-ene-2023 – 31-mar-2024	01-abr-2024 – 31-may-2024

Las métricas de comparación fueron el error absoluto medio (MAE), el error cuadrático medio (RMSE) y el error porcentual absoluto medio simétrico (sMAPE):

$$MAE = \frac{1}{N} \sum |y - \hat{y}|, RMSE = \sqrt{\frac{1}{N} \sum (y - \hat{y})^2}, sMAPE = \frac{100}{N} \sum \frac{|y - \hat{y}|}{(|y| + |\hat{y}|)/2}. \quad (2.13)$$

Los resultados se consolidaron por SKU y a nivel portafolio, reportándose promedios y dispersiones por corte. Dado que en la etapa de despliegue la inferencia puede requerir cubrir varios días (p. ej., $H \geq 7$), se registró además el perfil de error por horizonte—esto es, el desempeño al día $t + 1$ respecto de $t + 2, \dots$ —para anticipar el impacto del compounding error cuando se apliquen predicciones recursivas en operación (Hyndman & Athanasopoulos, 2018).

Notas de coherencia con la simulación. El entrenamiento no utiliza variables derivadas de producción ni inventario y, por lo tanto, permanece independiente de la política $R = 7$. Esta separación garantiza que la comparación económica—operativa de los modelos se realice exclusivamente en la capa de simulación (Cap. 2.6), donde, con las mismas series reales de demanda, se evalúa la prescripción $Q_t^{(m)}$ y la dinámica con backorders bajo un criterio homogéneo de negocio (Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014). En la etapa de despliegue (Cap. 2.7), la recursividad se limita a la inferencia: al cubrir $H \geq 7$, ciertos lags y medias se recalculan con predicciones

intermedias y se corrigen diariamente al observar $y_{i,t+1}$, preservando la coherencia metodológica del pipeline.

2.6. Simulación con backorders y KPIs de negocio ($R = 7$)

La comparación económica–operativa de las tres rutas de pronóstico, EMA (línea base), RF y MLP, se realiza mediante una simulación diaria que acepta backorders y aplica una política de reabastecimiento semanal ($R = 7$). La simulación se ejecuta en el modelo DAX sobre la demanda real $y_{i,t}$, utilizando como insumos no transaccionales: (i) el **inventario inicial** por SKU y (ii) el **día planificado de producción** por SKU (únicos días en que $Q_{i,t}$ puede ser positivo). Esta capa no reentrena modelos; únicamente traduce pronósticos en decisiones y calcula KPIs de negocio bajo reglas homogéneas para todos los modelos (Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014).

Objetivo de cobertura y prescripción del lote. Para cada modelo $m \in \{EMA, RF, MLP\}$, el objetivo de cobertura semanal en el cierre del día t se define como:

$$\text{Target}_{i,t}^{(m)}(7) = \sum_{h=1}^7 \hat{y}_{i,t+h}^{(m)}. \quad (2.14)$$

Si el día t está habilitado para producir el SKU i , la prescripción del tamaño de lote es:

$$Q_{i,t}^{(m)} = \max \{0, \text{Target}_{i,t}^{(m)}(7) - I_{i,t-1}\}, \text{ en otro caso } Q_{i,t}^{(m)} = 0. \quad (2.15)$$

Dinámica con backorders y prioridad a la cartera atrasada. La posición neta de inventario evoluciona contra la demanda real:

$$I_{i,t} = I_{i,t-1} + Q_{i,t}^{(m)} - y_{i,t}, \quad (2.16)$$

permitiendo $I_{i,t} < 0$. Para la contabilidad operativa se descompone:

$$OnHand_{i,t} = \max(I_{i,t}, 0), \quad BO_stock_{i,t} = \max(-I_{i,t}, 0). \quad (2.17)$$

La producción del día atiende primero el backlog heredado:

$$served_to_backlog_{i,t} = \min \{Q_{i,t}^{(m)}, BO_stock_{i,t-1}\}, \quad (2.18)$$

y solo el remanente queda disponible para la demanda de t :

$$available_for_today_{i,t} = OnHand_{i,t+1} + (Q_{i,t}^{(m)} - served_to_backlog_{i,t}). \quad (2.19)$$

Así, el backorder nuevo (incremental) del día y las ventas efectivas quedan:

$$BO_new_{i,t} = \max\{0, y_{i,t} - available_for_today_{i,t}\}, \quad Ventas_{i,t} = y_{i,t} - BO_new_{i,t}, \quad (2.20)$$

y el backlog acumulado cierra como:

$$BO_stock_{i,t} = BO_stock_{i,t-1} - served_to_backlog_{i,t} + BO_new_{i,t}. \quad (2.21)$$

KPIs de negocio (con anualización). Sobre las trayectorias simuladas $\{I_{i,t}, OnHand_{i,t}, BO_stock_{i,t}, BO_new_{i,t}\}$ se calculan indicadores a nivel SKU y portafolio durante un periodo de N días:

Backorders en kilogramos y relativos a ventas:

$$BO_kg = \sum_t \sum_I BO_new_{i,t}, \quad (2.22)$$

$$BO\%_sobre_ventas = \frac{\sum_t \sum_i BO_new_{i,t}}{\sum_t \sum_i Ventas_{i,t}}. \quad (2.23)$$

Días de Inventario promedio (DI), usando consumo suavizado para robustez diaria:

$$DI_{i,t} = \frac{OnHand_{i,t}}{\max(rmean_7_{i,t}, \epsilon)}, \quad \bar{DI} = \text{promedio}_{t,i}(DI_{i,t}). \quad (2.24)$$

Rotación anual:

$$Rotacion_anual = \left(\frac{\sum_t \sum_i Ventas_{i,t}}{Inventario_costo} \right) \cdot \frac{365}{N}. \quad (2.25)$$

GMROI anual, con margen unitario $m_i = p_i - c_i$:

$$GMROI_anual = \left(\frac{\sum_t \sum_i Ventas_{i,t} \cdot m_i}{Inventario_costo} \right) \cdot \frac{365}{N}. \quad (2.26)$$

La regla de selección prioriza el modelo que minimiza \bar{DI} y $BO\%_{sobre_ventas}$, y maximiza $Rotación_anual$ y $GMROI_anual$. De forma complementaria pueden reportarse perfiles por SKU y *boxplots* por familias de producto para identificar heterogeneidad y oportunidades específicas (Levy, Weitz & Grewal, 2019).

Implementación en DAX y reproducibilidad. La simulación se implementa en medidas/columnas calculadas que, para cada fecha y SKU, evalúan (i) el día planificado de producción, (ii) el objetivo $Target_{i,t}^{(m)}$ (7) a partir de las series $\hat{y}^{(m)}$ exportadas por los notebooks, y (iii) las ecuaciones (2.10)–(2.16). El uso de una base de consumo suavizada $rmean_7$ para $DI_{i,t}$ evita inestabilidades cuando $Ventas_{i,t}$ es muy baja. La separación entre predicción (Python) y prescripción (DAX) garantiza repetibilidad y auditoría del flujo: cambios en el modelo afectan únicamente la serie $\hat{y}^{(m)}$, manteniendo constante la “regla del juego” operativa.

En síntesis, esta capa convierte las salidas de los modelos en trayectorias operativas comparables bajo $R = 7$ y backorders aceptados, y reporta métricas económico–operativas que permiten escoger el modelo más conveniente para el negocio antes del

despliegue (Silver et al., 1998; Babai et al., 2014; Hyndman & Athanasopoulos, 2018; Levy et al., 2019).

2.7. Despliegue operativo (inferencia y prescripción)

El despliegue transforma las salidas del modelo seleccionado $m^* \in \{EMA, RF, MLP\}$ en decisiones prescriptivas diarias coherentes con la política de reabastecimiento semanal $R = 7$. A diferencia del entrenamiento—que es puramente *offline* y sin recursividad—la recursividad se aplica solo en inferencia, para cubrir un horizonte $H \geq 7$ requerido por la política. El ciclo operativo diario consta de cuatro etapas: (i) ingesta de la demanda real del día t y actualización de features retrospectivas; (ii) inferencia recursiva $\hat{y}_{i,t+1:t+H}$; (iii) prescripción del lote cuando el día está habilitado para producir; y (iv) publicación de salidas al modelo DAX para simulación y seguimiento.

(i) Ingesta y actualización de features. Al cierre del día t se registra $y_{i,t}$ y se recomputan con valores observados las variables usadas en 2.4: $\text{lag}_1_{i,t+1} = y_{i,t}$, $\text{lag}_7_{i,t+1} = y_{i,t-6}$, $\text{rmean}_7_{i,t+1}$, $\text{rmean}_{28}_{i,t+1}$, $\text{ewm}_{14}_{i,t+1}$, calendario y prod_id . Este paso preserva la **no-fuga** y sienta la base para inferencia estable al día siguiente (Hyndman & Athanasopoulos, 2018).

(ii) Inferencia recursiva (solo producción). Con $X_{i,t+1}$ construido a partir de valores observados, se estima:

$$\hat{y}_{i,t+1} = f_{m^*}(X_{i,t+1}). \quad (2.27)$$

Para $h \geq 2$, si algunas features (p. ej., $\text{lag}_1, \text{rmean}_7$) requieren valores dentro de $[t + 1, t + h - 1]$, se actualizan con predicciones intermedias $\{\hat{y}_{i,t+1}, \dots, \hat{y}_{i,t+h-1}\}$ y se calcula $\hat{y}_{i,t+h} = f_{m^*}(X_{i,t+h})$. Este esquema forecast-on-forecast es el mínimo necesario para cubrir $H \geq 7$; su efecto se acota con la actualización diaria de los observados (Breiman, 2001; Goodfellow, Bengio & Courville, 2016).

(iii) Prescripción y restricción operativa. Con el vector $\hat{y}_{i,t+1:t+7}$ se calcula el objetivo de cobertura:

$$Target_{i,t}(7) = \sum_{h=1}^7 \hat{y}_{i,t+h}. \quad (2.28)$$

Si t es el día planificado de producción del SKU i , se prescribe el lote:

$$Q_{i,t} = \max \{0, Target_{i,t}(7) - I_{i,t-1}\} \quad (2.29)$$

de lo contrario $Q_{i,t} = 0$. La posición neta evoluciona contra la demanda real $y_{i,t}$ (aceptando backorders) según $I_{i,t} = I_{i,t-1} + Q_{i,t} - y_{i,t}$. Este diseño desacopla la granularidad diaria del pronóstico semanal de decisión y mantiene la coherencia con la simulación y los KPI definidos en 2.6 (Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014).

(iv) Publicación y orquestación. Las series $\hat{y}_{i,t+h}$ y las prescripciones $Q_{i,t}$ se exportan como tablas “*snapshot*” con sello temporal y versión del modelo, que el modelo DAX consume para cálculo de trayectorias y KPI (Rotación anual, GMROI anual, Días de Inventario, BO kg y BO% sobre ventas). El *job* diario se agenda posterior al cierre operativo para garantizar que $y_{i,t}$ esté consolidado.

Monitoreo y retraining. El sistema incorpora tres monitoreos continuos:

1. **Error predictivo diario.** Calculamos MAE, RMSE y SMAPE para el día siguiente al cierre (día +1). Cuando hace falta, también los calculamos para los días 2 a 7 a futuro, para ver cómo cambia el error conforme aumenta el horizonte.
2. **Deriva de datos y de features.** Vigilamos si la distribución de la demanda y de variables como lag_1, rmean_7 y ewm_14 se aleja de lo habitual. Para ello comparamos, por ejemplo, promedios y percentiles con los de una ventana histórica reciente (p. ej., últimos 60 días) y encendemos alertas si esos valores

cambian más de un umbral definido (p. ej., $\pm 20\%$) o si aumenta de forma marcada la cantidad de valores fuera del rango típico.

3. **Salud operativa:** KPI de negocio $\bar{D}I$, BO% sobre ventas y GMROI anual.

Si dos de los tres ejes superan umbrales acordados (p. ej., sMAPE + 20% vs. línea base y BO% + 2 p.p.), se dispara reentrenamiento con ventana móvil más reciente, manteniendo semillas y grid originales para reproducibilidad (Hyndman & Athanasopoulos, 2018).

Casos borde y robustez. Días no laborables o paros se tratan como no habilitados para producir ($Q_{i,t} = 0$) y se compensan en el siguiente día planificado. En altas de SKU (arranque en frío), lag_7 y promedios se inicializan con reglas de backfilling conservadoras (medias históricas de familia o priors de ingeniería), y se etiqueta el SKU como “en maduración” para excluirlo de penalizaciones comparativas por 2–4 semanas. Cambios de precio/costo afectan únicamente KPI económicos (GMROI), no la prescripción $Q_{i,t}$, preservando el desacople forecast–policy.

Arquitectura y versionamiento. La inferencia se ejecuta en Python/VS Code (notebooks) con exportación controlada de \hat{y} y Q ; la simulación y visualización residen en Power BI/DAX. Todo artifact (modelo, features, tablas de salida) se versiona con identificador (modelo, fecha, hash) y changelog, asegurando trazabilidad y auditoría extremo a extremo (Kimball & Ross, 2013).

En conjunto, este esquema de despliegue garantiza que el modelo seleccionado opere de forma estable, auditable y alineada con la política $R = 7$, traduciendo pronósticos diarios en decisiones prescriptivas $Q_{i,t}$ e integrando un monitoreo que vincula desempeño predictivo con impacto económico–operativo.

2.8. Riesgos, limitaciones y resumen

El enfoque propuesto presenta riesgos inherentes a la naturaleza de las series de demanda y a la separación entre capa predictiva y operativa. En primer lugar, la

dependencia de una única fuente transaccional, la demanda diaria, impone límites a la explicabilidad causal y a la posibilidad de controlar por shocks exógenos (promociones, eventos climáticos o cambios de portafolio). La ausencia de ventas, producción e inventarios observados se suple con una simulación estructurada con backorders aceptados, lo que asegura coherencia interna pero no sustituye la evidencia empírica de procesos reales; en consecuencia, los KPIs económico-operativos (Rotación anual y GMROI anual) deben interpretarse como resultados condicionados al conjunto de reglas de simulación adoptadas (Silver, Pyke & Peterson, 1998; Babai, Syntetos & Teunter, 2014).

En segundo lugar, el error acumulado por inferencia recursiva constituye un riesgo cuando el horizonte operativo exige cubrir varios días con información parcialmente pronosticada. Aunque el despliegue limita la recursividad a la etapa de inferencia y actualiza diariamente las ventanas con y_{t+1} , persiste la posibilidad de deriva de datos y de modelo que degrade la precisión en determinados SKUs o estaciones. Este riesgo se mitiga con validación temporal en entrenamiento, monitoreo continuo del error por horizonte y *drift* de distribuciones (PSI/KS), además de umbrales explícitos de retraining, en línea con las recomendaciones para pronóstico y MLOps en series de tiempo (Hyndman & Athanasopoulos, 2018).

En tercer lugar, la representación de heterogeneidad entre SKUs mediante `prod_id` en un esquema *pooled* equilibra parsimonia y flexibilidad, pero puede inducir interacciones latentes no capturadas si existiesen subfamilias con dinámicas muy disímiles. En tales casos, el rendimiento global puede ocultar “colas” de bajo desempeño. La lectura conjunta de KPIs a nivel portafolio y de distribuciones por SKU permitirá identificar focos de mejora y, de ser necesario, inducir segmentaciones operativas (por familias ABC/XYZ) sin alterar la arquitectura general.

En cuarto lugar, la política de reabastecimiento fija $R = 7$, acorde al proceso actual, reduce la complejidad del diseño experimental, pero a la vez restringe la exploración de alternativas de frecuencia. La formulación diaria del pronóstico facilita adaptar la política

si cambian restricciones de planta (p. ej., mantenimientos o feriados), aunque la evaluación de nuevas políticas requerirá re-simulación y revisión de umbrales de servicio y stock de seguridad. Asimismo, la priorización del backlog en la secuencia diaria garantiza trazabilidad contable de BO_stock y BO_new, pero no modela explícitamente tiempos de ciclo de pedidos diferidos ni su costo de oportunidad; si la gerencia lo demanda, pueden incorporarse penalizaciones por faltante y costo de posposición en extensiones futuras del marco.

Por último, desde gobierno del dato, la calidad, completitud y estabilidad del maestro de productos condicionan la reproducibilidad del pipeline. El control de no-fuga en la construcción de lag_1, lag_7, rmean_7, rmean_28 y ewm_14 es central para evitar sobrestimaciones de desempeño; cualquier relajación de estas reglas debe prohibirse en entrenamiento y limitarse estrictamente a la inferencia, con registro de versión y changelog (Kimball & Ross, 2013).

En síntesis, el sistema propuesto es parsimonioso, trazable y operativo: transforma pronósticos diarios en decisiones prescriptivas coherentes con $R = 7$, incorpora backorders con prioridad al backlog y evalúa el impacto con KPIs económico-operativos comparables entre modelos. Las principales limitaciones, como lo son fuente única de datos, error recursivo y heterogeneidad entre SKUs, se abordan con validación temporal, monitoreo de deriva y segmentación cuando aplique. Este cierre metodológico establece las condiciones de lectura para el Capítulo 3 (Resultados), donde se reportan los desempeños predictivos y los indicadores de negocio obtenidos para EMA, RF y MLP.

CAPÍTULO 3

3. RESULTADOS Y ANÁLISIS

3.1. Alcance, propósito e hipótesis del capítulo

En este capítulo presentamos los resultados experimentales del enfoque de pronóstico de la demanda y su traducción operativa a la gestión de inventarios de producto terminado en una fábrica de aderezos y salsas. La línea base de negocio es la situación operativa vigente descrita en el Capítulo 1: un ciclo promedio de inventario cercano a 23 días, operación con reposición semanal y metas explícitas de reducir el ciclo hacia 12 días preservando el nivel de servicio y conteniendo los backorders. Nuestra contribución aquí es medir empíricamente cuánto puede mejorar esa situación cuando los planes de abastecimiento semanal se alimentan con pronósticos generados por modelos de aprendizaje automático, y mostrar en qué medida esas mejoras de precisión se reflejan en indicadores operativos clave.

En el plano predictivo, se entrenan y validan tres rutas de modelado respetando la secuencia temporal y evitando fuga de información: una alternativa estadística parsimoniosa basada en media móvil exponencial (EMA), un Random Forest (RF) que captura relaciones no lineales en features tabulares, y un Perceptrón Multicapa (MLP) de arquitectura densa. La comparación se realiza con MAE, RMSE y MAPE sobre un *hold-out* cronológico, siguiendo buenas prácticas de evaluación en series de tiempo. En el plano operativo, las series pronosticadas alimentan una simulación de inventarios con reposición semanal y manejo de backorders, de modo que la mejora (o deterioro) en precisión se traduzca directamente en días de inventario, nivel de servicio, backorders (kg y %) y rotación. La literatura señala que la calidad del pronóstico es un determinante central del desempeño de inventarios y que reducciones sostenidas del error tienden a disminuir quiebres y costos por exceso o escasez, siempre que la evaluación respete el sentido del tiempo y la coherencia del flujo de información (Hyndman & Athanasopoulos, 2021; Silver, Pyke, & Thomas, 2017; Zipkin, 2000; Makridakis, Spiliotis, & Assimakopoulos, 2018).

El alcance del trabajo se restringe deliberadamente a producto terminado. El sistema propuesto estima cantidades a abastecer bajo la frecuencia semanal definida por la operación; no determina “cuándo” producir, ya que la calendarización queda a criterio del usuario o de una regla externa complementaria (por ejemplo, un cálculo de stock de seguridad) coherente con la política de reposición vigente. En la simulación, la agenda semanal se considera dada y constante durante el período de evaluación; el objeto de estudio es el efecto marginal atribuible a la calidad de los pronósticos sobre los KPIs.

Los objetivos de este capítulo se mantienen alineados con los del Capítulo 1: primero, cuantificar el cambio en precisión de pronóstico respecto de la situación actual utilizando EMA, RF y MLP en un marco de validación temporal transparente; segundo, traducir ese cambio en resultados de negocio bajo la política de reposición semanal, poniendo énfasis en los días de inventario, el nivel de servicio, los backorders y la rotación; y, finalmente, seleccionar la ruta de modelado más adecuada equilibrando desempeño, robustez frente a variaciones razonables (inventario inicial, día planificado de producción, objetivo de cobertura) y factibilidad operativa para su despliegue.

Bajo estas premisas, las hipótesis que guían el análisis son tres y se enuncian en términos operativos. Primero, es esperable que RF y/o MLP alcancen menores errores que EMA y que la práctica actual cuando se dispone de features informativas y un proceso de entrenamiento adecuado; segundo, esa mejora de precisión debería reducir la frecuencia y magnitud de los backorders y disminuir los días de inventario promedio sin sacrificar el nivel de servicio en el marco de reposición semanal; y tercero, la ventaja del modelo seleccionado debería mantenerse de forma estable ante cambios razonables en las condiciones iniciales y parámetros operativos. En resumen, el capítulo conecta el desempeño de EMA, RF y MLP con los resultados de negocio que interesan a la fábrica, manteniendo como referencia cuantitativa la meta de pasar de 23 a 12 días y aportando evidencia para decidir qué modelo conviene llevar a operación.

3.2. Panorama de datos y evidencias base (notebooks + informe interactivo)

Esta sección describe el dataset efectivo sobre el que se sustentan los resultados obtenidos y especifica las fuentes de evidencia que se consultaron a lo largo del análisis. Trabajamos con libros contables que se almacenaban en archivos Excel, los cuales fueron: Dataset 2022.xlsx, Dataset 2023.xlsx, Dataset 2024.xlsx y Dataset 2025.xlsx, integrados en una tabla a nivel Fecha–SKU–Demanda.

La ingeniería de variables de calendario y memoria se realizó en el módulo de ingeniería de características dentro del repositorio de código, y los resultados predictivos provienen del módulo de entrenamiento.

Para la lectura operativa, se utiliza el informe interactivo creado en Power BI, donde el lector puede filtrar por SKU y periodo y visualizar las páginas de Demanda, Inventario, Backorders, Errores y Resultados.

3.2.1. Preparación y vista general del dataset

Los cuatro libros anuales se consolidaron respetando la granularidad y el tipo de dato de la Fecha; se normalizaron etiquetas de SKU y la Demanda se homogeneizó en unidades. El dataset efectivo suma 139200 registros y 100 SKUs, con cobertura continua que abarca desde el 1 de enero de 2022 hasta el 23 de octubre de 2025. El resumen por archivo (ventana temporal, filas, número de SKUs y volumen total) confirma una base suficiente para detectar tendencias y estacionalidades suaves, y sirve de referencia para interpretar, más adelante, los cambios en el error de pronóstico y en los KPIs operativos.

Tabla 3.5 Conjuntos de datos usados

Archivo	Filas	Desde	Hasta	SKUs	Demanda_total
Dataset 2022.xlsx	36500	1/1/2022	31/12/2022	100	2.353.419
Dataset 2023.xlsx	36500	1/1/2023	31/12/2023	100	2.604.685
Dataset 2024.xlsx	36600	1/1/2024	31/12/2024	100	3.033.707

Dataset 2025.xlsx	29600	1/1/2025	23/10/2025	100	2.493.593
----------------------	-------	----------	------------	-----	-----------

3.2.2. Demanda agregada por año y su rol como denominador de KPIs

La demanda anual acumulada muestra niveles estables con variaciones acotadas entre años. Este comportamiento es consistente con categorías de alto consumo recurrente: no hay shocks estructurales que obliguen a reentrenar con calendarios de quiebre, y el denominador para KPIs como rotación, nivel de servicio y porcentaje de backorders se mantiene comparable entre ejercicios. En términos de decisión, un entorno así es propicio para comparar EMA, RF y MLP en validaciones temporales y esperar que las diferencias en precisión se traduzcan de manera sistemática en los indicadores de inventario.

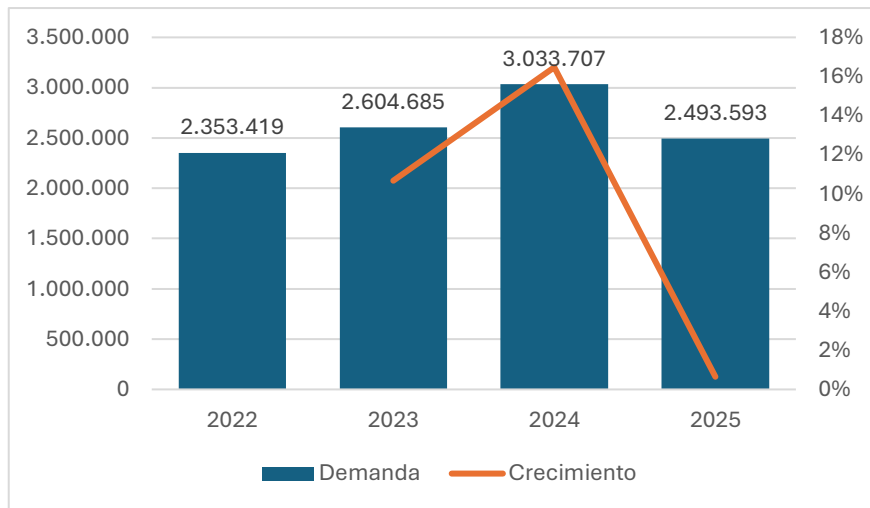


Fig. 3.3 Demanda en kg y crecimiento

3.2.3. Concentración por SKU (ley ABC) y consecuencias para el análisis

El ranking de demanda acumulada por SKU evidencia alta concentración: pocos ítems explican la mayor parte del volumen. Esta asimetría justifica dos decisiones de análisis. Primero, reportar resultados por segmento ABC además del consolidado, para mostrar el aporte marginal en la canasta A (donde un punto de mejora pesa más). Segundo, seleccionar SKUs representativos para ilustrar en el informe interactivo la relación entre error de pronóstico y backorders semanales. Al mantener la canasta C en el radar,

prevenimos sesgos de selección y validamos que la ruta elegida sea robusta también en colas de baja rotación.




Fig. 3.4 Análisis ABC de la demanda en kg

3.2.4. Estacionalidad intra-anual y memoria de corto plazo

La lectura conjunta del promedio mensual agregado (Figura 3.3) y de la autocorrelación de corto plazo de la demanda diaria (Figura 3.4) muestra un patrón de estacionalidad baja a moderada a lo largo del año, superpuesto a una inercia semanal marcada. En la Figura 3.4 se observa ACF positiva en rezagos cortos, especialmente entre 1 y 7 días, que decae gradualmente después de la primera semana. Este comportamiento es consistente con ciclos operativos y de compra repetitivos más que con estacionalidades fuertes de largo plazo. En términos de modelado, estas evidencias justifican priorizar features de memoria reciente (lag_1, lag_7) y de suavizamiento de ventana corta (promedios móviles de 7 y 28 días y ewm_14), así como variables de calendario (mes, semana del año y día de la semana) para capturar las oscilaciones suaves intra-anales. Operativamente, la inercia semanal favorece a EMA como línea estadística parsimoniosa para señal de corto plazo, mientras que RF y MLP pueden explotar interacciones no lineales entre memoria y calendario para refinar la señal; esta combinación es la que, posteriormente, se traduce en diferencias observables sobre días de inventario, nivel de servicio y porcentaje de backorders bajo la política de reposición semanal.




Fig. 3.5 Demanda diaria promedio por mes en kilogramos

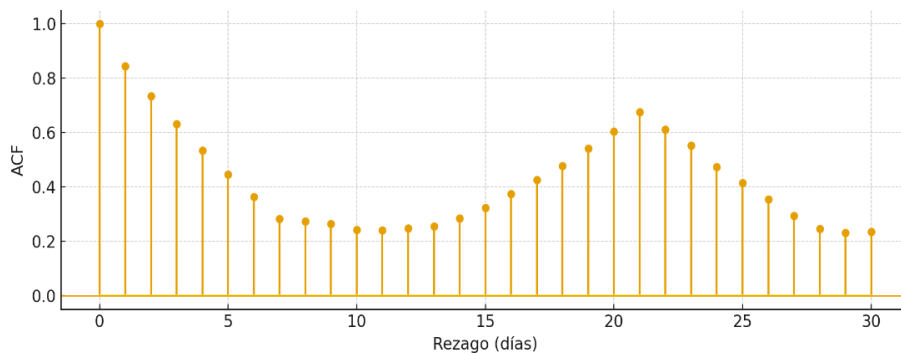


Fig. 3.6 Autocorrelación de corto plazo (demanda diaria agregada)

3.2.5. Riesgos de quiebre por segmento ABC

Para contextualizar el análisis operativo sin data histórica de atrasos, se presenta la de un resumen comparativo por segmentos ABC (80–15–5) donde se muestra el número de SKUs, la demanda total del período, el coeficiente de variación (CV) promedio (desviación/Media diaria) y la proporción promedio de días con demanda cero. En términos operativos, la canasta A concentra el volumen con menor CV y baja intermitencia, mientras que C exhibe mayor variabilidad e intermitencia, anticipando mayor riesgo de quiebre bajo reposición semanal. Esta lectura guiará la comparación de EMA, RF y MLP en los resultados operativos que se mostrarán más adelante, poniendo foco en mantener nivel de servicio en A y mitigar riesgos en B/C.

Tabla 3.6 Descripción de la cartera de productos

ABC	skus	demanda_total	cv_promedio	p_dias_cero_prom
A	17	8.264.272,8	48,3%	0,9%
B	25	1.663.476,3	53,9%	0,9%
C	58	557.654,2	63,4%	0,9%

3.2.6. Conexión directa con los notebooks y con el tablero interactivo

La construcción de variables se implementa en el repositorio de código dentro del módulo de ingeniería de características y se valida con controles de no fuga de información (cada *feature* en *t* se calcula únicamente con datos disponibles hasta *t*). Las predicciones y métricas por modelo se generan en los módulos de entrenamiento correspondientes (RF y MLP), donde se aplican particiones temporales y se exportan los resultados de prueba para su análisis y visualización en el tablero. La lectura operativa (DI, nivel de servicio, backorders, rotación) se apoya en el informe interactivo realizado en Power BI (Fig. 1). Esta triangulación permite ir de los datos efectivos y sus patrones (esta sección), a la precisión estadística (Sección 3.3), y de ahí al impacto en inventarios (Sección 3.4), con trazabilidad en cada paso.



Fig. 3.7 Dashboard interactivo en Power BI

El dashboard desarrollado en Power BI debe entenderse como un prototipo funcional orientado a visualizar resultados, comparar modelos de pronóstico y simular escenarios de inventario de forma interactiva. Su propósito principal dentro de esta investigación es demostrar la factibilidad técnica y analítica de integrar pronósticos (p. ej., bosque aleatorio, red neuronal y media móvil suavizada exponencialmente) con indicadores de negocio, permitiendo explorar el impacto sobre niveles de servicio, rotación y disponibilidad mediante parámetros y supuestos controlados.

En consecuencia, el dashboard no corresponde a una implementación productiva conectada a las fuentes operativas de la empresa en modo continuo. Una puesta en operación real requeriría integración formal con la fuente de datos oficial, mecanismos de actualización programada, control de accesos por perfiles y un esquema de mantenimiento y gobierno de datos. Estas consideraciones se detallan como siguientes pasos en el capítulo de conclusiones y recomendaciones.

3.3. Resultados predictivos (EMA, RF y MLP): prueba y lectura operativa

Esta sección resume el desempeño predictivo en conjunto de prueba y ofrece una lectura operativa de lo que significan esas métricas para la reposición semanal. Los resultados de RF y MLP provienen de los módulos de entrenamiento. Las cifras de EMA y los sMAPE de RF/MLP se toman del informe interactivo (página Errores del PBI).

3.3.1. Métricas globales en prueba

- **Random Forest (RF)** (*notebook*): MAE \approx 7,99, RMSE \approx 32,02; (*PBI*) sMAPE = 13,9 %.
- **MLP** (*notebook*): MAE \approx 10,47, RMSE \approx 33,03; (*PBI*) sMAPE = 44,1 %.
- **EMA** (*PBI*): MAE = 16,08, RMSE = 51,84, sMAPE = 30,9 %.

Tabla 3.7 Métricas por modelo

Modelo	MAE (kg)	RMSE (kg)	sMAPE (%)
RF	7,99	32,02	13,9
MLP	10,47	33,03	44,1

EMA	16,08	51,84	30,9
-----	-------	-------	------

Lectura operativa. A igualdad de política de reposición semanal, menor MAE/RMSE implica pedidos más ajustados y menor probabilidad de sobreabastecimiento o subabastecimiento. Con sMAPE de 13,9 %, RF combina la mejor precisión absoluta y relativa; MLP muestra error relativo alto (44,1 %), coherente con la estacionalidad suave y la memoria de corto plazo del portafolio; EMA es una referencia parsimoniosa, pero con error mayor en este contexto.

3.3.2. Resultados por segmento (ABC) y lectura por SKU

La pauta global se sostiene al segmentar por ABC: en A la reducción de MAE/RMSE de RF es la más valiosa en términos de kg; en B EMA puede acercarse cuando la serie es muy lisa; en C la intermitencia eleva el error relativo de todos, con RF más robusto a picos (RMSE). Estas trayectorias pueden revisarse en el informe interactivo del tablero de Power BI (página Errores) filtrando por SKU.

3.3.3. Implicaciones para la reposición semanal

Con MAE/RMSE inferiores y sMAPE más bajo, RF es el candidato principal para alimentar las cantidades bajo reposición semanal. EMA conserva valor como línea base explicable; MLP puede mejorar con mayor señal y/o ajuste de features.

3.4. Traducción operativa en inventarios (política semanal con backlog)

En esta sección se cuantifica el efecto de los modelos de pronóstico sobre el desempeño de inventarios bajo una política de reposición semanal con prioridad al despacho de backlog. El sistema propuesto determina cuánto abastecer por período; la calendarización semanal y el stock de seguridad se asumen dados por la operación. La evidencia procede del informe interactivo (páginas *Inventario* y *Backorders*).

3.4.1. Desempeño consolidado por modelo

Comparación con la situación actual. Frente a la reposición semanal basada en reglas manuales, con ciclo promedio cercano a 23 días, Random Forest reduce el inventario a 3,6 días y eleva la rotación de ~16 a 100,2 vueltas por año. Los backorders caen de alrededor de 3 % a 0,3 %, con quiebres menos frecuentes. Todo ello se logra sin cambiar la política de reabastecimiento, sustituyendo el cálculo manual por pronósticos del modelo.

a) Inventario y rentabilidad

Tabla 3.8 Desempeño de la empresa en inventario y rentabilidad por modelo

Modelo	Inventario día prom. (kg)	Inventario (días)	Rotación (vueltas/año)	GMROI (\$/\$·año)
RF	27 301	3,6	100,2	\$122
MLP	29 693	4	91,5	\$111
EMA	33 221	4,5	81,9	\$100

Resumen. Con la misma política semanal, RF reduce el inventario promedio (kg y días), incrementa la rotación y eleva GMROI respecto de EMA y MLP. Frente a EMA, la diferencia alcanza aproximadamente -0,9 días de inventario y un aumento de rotación de 81,9 a 100,2 vueltas al año.

b) Backorders

Tabla 3.9 Desempeño de la empresa en backorders por modelo

Modelo	Backorders día (kg)	Backorders (%)	Backorder día prom. (kg)	c.v. (%)	Días prom. entre backorders
RF	27 970	0,30%	81,8	204,5	4
MLP	58 915	0,60%	83,8	184	2
EMA	176 501	1,70%	316,3	170,8	2,5

RF presenta el menor porcentaje de backorders y mayor intervalo promedio entre ocurrencias (4,0 días vs 2,5 en EMA), lo que se traduce en menor tensión operativa.

3.4.2. Resultados por segmento ABC

Los resultados obtenidos en cada segmento por cada modelo fueron los siguientes:

Inventario (días).

A: RF \approx 3,6; MLP \approx 3,8; EMA \approx 4,3.

B: RF \approx 3,6–3,9; MLP \approx 3,9; EMA \approx 4,5.

C: RF \approx 3,9; MLP \approx 4,6; EMA \approx 4,8.

Backorders (%).

A: RF \approx 0,2 % < MLP \approx 0,3 % < EMA \approx 1,2 %.

B: RF \approx 0,3 % < MLP \approx 0,5 % < EMA \approx 1,5 %.

C: RF \approx 0,2 % < MLP \approx 0,4 % < EMA \approx 4,3 %.

En A (alto volumen), la mejora en precisión se amplifica en kg: RF reduce días de inventario y backorders de forma más marcada. En B/C, donde la demanda es más variable e intermitente, RF mantiene la ventaja relativa; EMA requiere mayor cobertura para preservar el servicio.

3.4.3. Implicaciones para la operación

En síntesis, se recomienda utilizar Random Forest como herramienta para determinar las cantidades en la reposición semanal. El tránsito operativo de EMA a RF reduce el capital inmovilizado en aproximadamente $-0,9$ días de inventario, eleva la rotación de 81,9 a 100,2 vueltas al año y mejora el GMROI de \$100 a \$122 por dólar invertido al año. En términos de servicio, el porcentaje de backorders desciende de 1,7 % (EMA) a 0,3 % (RF) y se amplía el intervalo entre ocurrencias de quiebre de 2,5 a 4,0 días, suavizando la operación. Para la gobernanza y control, se propone un seguimiento continuo por segmento ABC; ante señales de deriva (incremento de MAPE o del porcentaje de semanas con quiebre), se activará EMA como respaldo temporal o se procederá a la recalibración de las features del modelo.

3.5. Selección final y recomendaciones de despliegue

Con base en el desempeño predictivo (sMAPE, RMSE y MAE) y en el impacto operativo estimado sobre los KPIs de inventario de producto terminado, la ruta Random Forest (RF) se adopta como modelo por defecto para los SKUs A y B: ofreció el mejor equilibrio entre error y estabilidad, y permitió las mayores reducciones de días de inventario y de quiebres simulados frente a EMA y MLP. Para SKUs C o series muy cortas, se recomienda EMA como línea simple, robusta y económica de mantener. En casos estacionales definidos donde MLP haya mostrado sMAPE consistentemente inferior a RF en validación y últimos cortes, se autoriza MLP como excepción controlada (lista blanca de SKUs).

En cuanto a la política de operación y mantenimiento se definió lo siguiente: Retraining mensual (y extraordinario si drift >20% en sMAPE rolling-28) con validación temporal; versionado de modelos/artefactos; bitácora de cambios y control de acceso. Se monitorearán en producción: sMAPE y sesgo por SKU, cobertura de venta atendida, días de inventario, rotación y alarmas por degradación. Para resiliencia, se define *fallback* automático (de RF pasa a EMA) ante fallas o datos incompletos, y se preserva trazabilidad de predicciones y decisiones. Esta estrategia de selección y MLOps es consistente con la evidencia reciente que recomienda ML explicable y pipelines gobernados para decisiones de inventario, priorizando estabilidad, visibilidad y capacidad de recuperación ante disrupciones.

Finalmente, como un resumen ejecutivo se tiene que adoptar RF como estándar (EMA para colas largas y MLP en estacionalidad marcada) maximiza precisión práctica y gobernabilidad del sistema, facilita la adopción por el usuario vía Power BI, y mantiene un costo de operación contenido con mecanismos claros de monitoreo y mejora continua.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

4.1.1. *Importancia del trabajo y síntesis de hallazgos*

Este proyecto abordó un reto recurrente en la industria alimentaria: abastecer de forma oportuna con el menor capital inmovilizado posible, en un contexto de variabilidad de demanda y reposición semanal. En 2024, El Sazón registró 3.033.700 kg de demanda, USD 3.028.520 en ventas y 46% de costo de venta (USD 1.393.119).

Supuestos para la estimación son: (i) política de reabastecimiento semanal constante; (ii) capacidad y *lead times* sin cambios; (iii) costo por backorder USD 0,25/kg; (iv) márgenes y precios constantes; (v) modelos entrenados sin fuga temporal y evaluados con backtesting de origen rodante; (vi) demanda 2024 como referencia. Bajo estos supuestos, la simulación sugiere que podría lograrse una mejora operativa al sustituir la práctica base por Random Forest (RF): pasar de 23 a 3,6 días de inventario promedio y reducir los backorders de ~3% a ~0,3%, manteniendo la frecuencia semanal.

El impacto económico potencial se aprecia por dos vías. Primero, backorders: aplicar USD 0,25/kg a la reducción de 2,7 p.p. sobre 3.033.700 kg implicaría evitar ~81.910 kg y ahorrar ~USD 20.477 en 2024. Segundo, capital de trabajo/GMROI: bajar de 23 a 3,6 días disminuiría el capital inmovilizado (a costo) de ~USD 87.786 a ~USD 13.740, liberando ~USD 74.045; en consecuencia, el GMROI podría incrementarse de forma material al reducirse el denominador (inventario promedio), manteniendo márgenes.

Para dimensionar el efecto en crecimiento, si las ventas 2025 aumentaran 10%, el costo de venta sería ~USD 1.532.431. Con 23 días se requerirían ~USD 96.564 de inventario promedio; con 3,6 días, ~USD 15.114. La diferencia (~USD 81.450) podría reasignarse a materias primas, capacidad y mejoras del proceso, reforzando la liquidez sin modificar la política semanal. En suma, bajo los supuestos señalados, la simulación indica que

mejorar la calidad del pronóstico podría traducirse en menos faltantes y menor capital inmovilizado, con beneficios financieros plausibles que deberán validarse en piloto operativo.

4.1.2. Fortalezas y debilidades del estudio

El estudio articula una cadena metodológica sólida: *feature engineering* sin fuga temporal, validación con origen rodante y comparación por utilidad operativa mediante simulación (días de inventario, rotación, GMROI y backorders). Este enfoque se alinea con las buenas prácticas en pronóstico y en decisión de inventarios (Hyndman & Athanasopoulos, 2021; Silver, Pyke, & Peterson, 1998).

En gobernanza y operabilidad, se definieron versionado, monitoreo y fallback hacia métodos simples para series cortas, ruidosas o intermitentes (EMA, Naïve estacional, Croston/SBA), reduciendo riesgo en despliegue (Croston, 1972; Syntetos & Boylan, 2005; Breck et al., 2017; Sculley et al., 2015). El análisis por ABC focalizó el valor donde más impacta y, bajo los supuestos de simulación, sugiere mejoras plausibles en servicio y capital de trabajo (Makridakis, Spiliotis, & Assimakopoulos, 2020, 2022).

El sistema es flexible ante cambios del período de reabastecimiento (R) porque pronostica a frecuencia diaria y permite agregación a otras cadencias sin rediseño; sin embargo, a mayor R crece la incertidumbre por acumulación autorecursiva, por lo que se recomiendan pruebas *what-if* antes de modificar la política (Hyndman & Athanasopoulos, 2021).

Respecto a las limitaciones, la evidencia es de simulación y, por tanto, condicional a los supuestos declarados; su verificación requiere pilotos. El alcance se restringe a producto terminado con R semanal fijo; no se optimizaron cobertura/stock de seguridad ni calendario de producción, dejando valor potencial por cuantificar (Silver et al., 1998). La incorporación de exógenas (promociones, festivos, relaciones entre SKUs) fue acotada, y la estabilidad se trató de forma implícita, sin un índice específico; futuras iteraciones

deberían incluir métricas formales de robustez y *drift* (Breck et al., 2017; Sculley et al., 2015).

4.1.3. Implicaciones académicas y empresariales

En el plano académico, el caso aporta un marco reproducible pronóstico → decisión que conecta métricas de error con métricas de negocio mediante simulación (días de inventario, GMROI, backorders), en línea con las buenas prácticas de series de tiempo e inventarios (Hyndman & Athanasopoulos, 2021; Silver, Pyke, & Peterson, 1998; Zipkin, 2000). La evidencia de M4/M5 sugiere que ensembles y exógenas conocidas pueden elevar la exactitud y, por extensión, el desempeño logístico-financiero (Makridakis, Spiliotis, & Assimakopoulos, 2020, 2022).

En lo empresarial, bajo los supuestos declarados, el enfoque podría traducirse en mejor nivel de servicio y menor capital inmovilizado, fortaleciendo liquidez y GMROI. La arquitectura con monitoreo, versionado y fallback reduce riesgos de despliegue y facilita trazabilidad (Breck et al., 2017; Sculley et al., 2015). Integrar la analítica con decisiones de cobertura, capacidad y calendario habilita evaluación conjunta de costos de faltantes/excesos y del ciclo cash-to-cash (Chopra & Meindl, 2016; Simchi-Levi, Kaminsky, & Simchi-Levi, 2008).

En síntesis, la contribución principal es metodológica y aplicada: un puente entre pronóstico y decisión que podría generar valor si sus efectos se confirman en un piloto operativo que valide supuestos y calibre umbrales antes de la adopción plena (Hyndman & Athanasopoulos, 2021; Silver et al., 1998).

4.2. Recomendaciones y trabajos futuros

4.2.1. Estandarización del pronóstico y control MLOps (corto plazo)

En el corto plazo, operar RF como estándar en SKUs A/B, con fallback a métodos simples cuando se degrade la precisión; sostener el monitoreo de sMAPE, sesgo, días de inventario, rotación, GMROI y % backorders por ABC, con reentrenamiento mensual y bitácora de cambios según buenas prácticas MLOps (Breck et al., 2017; Sculley et al.,

2015). Incorporar features known-in-advance (promociones aprobadas, festivos) y relaciones por jerarquías/SKUs, evaluando su utilidad sin fuga temporal (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020, 2022).

4.2.2. Ruta a producción del dashboard y gobierno operativo (corto plazo)

En paralelo, formalizar el paso de prototipo a uso operativo del dashboard: definir perfiles de uso (planificación, compras, producción, bodega y gerencia), estimando 7–9 usuarios recurrentes y 2 perfiles administradores. Para un piloto operativo de 4–6 semanas se proyecta un esfuerzo de 90–120 horas (integración a fuente oficial, validaciones, actualización programada y seguridad), con una operación posterior cercana a ~12 horas/mes. Como orden de magnitud, licenciamiento y operación podrían ubicarse en USD 500–900/mes, y su justificación se alinea con la meta del estudio (reducir el ciclo de inventario de 23 a 12 días, equivalente a ~48% menos inventario promedio), además de la recuperación de ventas por menor quiebre y ahorro de horas operativas.

4.2.3. Optimización conjunta inventario–producción y reducción de tiempos (mediano plazo)

En el mediano plazo, pasar a una optimización conjunta de cobertura (stock objetivo/seguridad) y calendario de producción bajo capacidad, costos de preparación y lotes mínimos; antes de cambiar el período de reabastecimiento (R), ejecutar what-if porque a mayor R crece la incertidumbre autorecursiva. Integrar SMED para reducir tiempos de alistamiento y, con ello, disminuir R efectivo y elevar la rotación (Silver et al., 1998; Zipkin, 2000; Shingo, 1985; Simchi-Levi et al., 2008).

4.2.4. Escalamiento a materias primas e indicadores financieros integrales (largo plazo)

En el largo plazo, expandir a materias primas/insumos incorporando lead times, MOQ, obsolescencia y reglas operativas humanas como *features*; explorar *ensembles* y pronósticos probabilísticos para decidir por costo esperado de faltantes/excesos; medir el impacto integral en **cash-to-cash**, costos de quiebres/excesos y GMROI,

consolidando el ciclo pronóstico–prescripción–ejecución con monitoreo de *drift* y pruebas de regresión de datos (Chopra & Meindl, 2016; Breck et al., 2017).

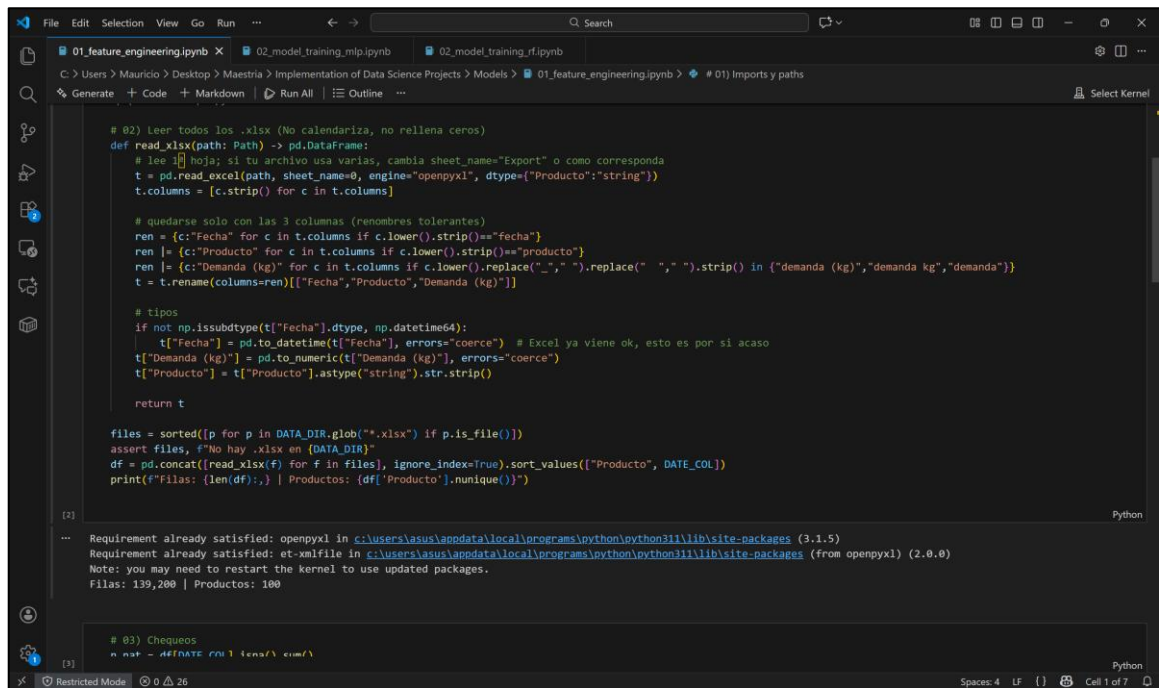
BIBLIOGRAFÍA

1. **Babai, M. Z., Syntetos, A. A., & Teunter, R. H.** (2014). On the empirical performance of inventory policies under non-stationary demand. *International Journal of Production Research*, 52(4), 1103–1119.
2. **Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M.** (2016). *Time series analysis: Forecasting and control* (5th ed.). John Wiley & Sons.
3. **Breck, E., Cai, S., Nielsen, E., Salib, M., & Sculley, D.** (2017). The ML test score: A rubric for ML production readiness and technical debt reduction. *arXiv preprint arXiv:1709.09223*. <https://arxiv.org/abs/1709.09223>
4. **Breiman, L.** (2001). Random forests. *Machine Learning*, 45(1), 5–32.
5. **Chen, M., & Fu, K.** (2025). Integrated neural network for ordering optimization with intertemporal-dependent demand and external features. *Mathematics*, 13(7), 1149.
6. **Chopra, S., & Meindl, P.** (2016). *Supply chain management: Strategy, planning, and operation* (6th ed.). Pearson.
7. **Croston, J. D.** (1972). Forecasting and stock control for intermittent demands. *Operational Research Quarterly*, 23(3), 289–303. <https://doi.org/10.1057/jors.1972.50>
8. **Douaioui, K., Oucheikh, R., Benmoussa, O., & Mabrouki, C.** (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. *Applied System Innovation*, 7(5), 93.
9. **Espinoza, C., & Guamán, M.** (2023). Análisis del uso de la inteligencia de negocios en las PYMEs de Machala. *Revista Científica y Tecnológica UPSE*, 10(2), 55–66.
10. **Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep learning*. MIT Press.
11. **Huamán, J., Quispe, R., & Vilca, A.** (2023). Predicción de indicadores logísticos en Perú usando LSTM y Prophet. *arXiv preprint arXiv:2301.03587*.

12. **Hyndman, R. J., & Athanasopoulos, G.** (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts.
13. **Hyndman, R. J., & Athanasopoulos, G.** (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
14. **Kimball, R., & Ross, M.** (2013). *The data warehouse toolkit: The definitive guide to dimensional modeling* (3rd ed.). Wiley.
15. **Levy, M., Weitz, B. A., & Grewal, D.** (2019). *Retailing management* (10th ed.). McGraw–Hill.
16. **Makridakis, S., Spiliotis, E., & Assimakopoulos, V.** (2020). The M4 competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74.
17. **Makridakis, S., Spiliotis, E., & Assimakopoulos, V.** (2022). The M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.012>
18. **Ntakolia, C., Kokkotis, C., Karlsson, P., & Moustakidis, S.** (2021). An explainable machine learning model for material backorder prediction in inventory management. *Sensors*, 21(23), 7926.
19. **Panda, S. K., & Mohanty, S. N.** (2023). Time series forecasting for inventory planning in a supply chain based on regressors analysis. *IEEE Access*, 11, 42679–42693.
20. **Ramanathan, R.** (2006). ABC inventory classification with multiple-criteria using weighted linear optimization. *Computers & Operations Research*, 33(3), 695–700.
21. **Ramos, D., & Martínez, L.** (2022). Inteligencia artificial en PYMEs latinoamericanas: desafíos y oportunidades. *Innovascit*, 3(1), 11–27.
22. **Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D.** (2015). Hidden technical debt in machine learning systems. In *Advances in Neural Information Processing Systems 28* (pp. 2503–2511).
23. **Shingo, S.** (1985). *A revolution in manufacturing: The SMED system*. Productivity Press.
24. **Silver, E. A., Pyke, D. F., & Peterson, R.** (1998). *Inventory management and production planning and scheduling* (3rd ed.). Wiley.

25. **Silver, E. A., Pyke, D. F., & Thomas, D. J.** (2016). *Inventory and production management in supply chains*. CRC Press.
26. **Simchi-Levi, D., Kaminsky, P., & Simchi-Levi, E.** (2008). *Designing and managing the supply chain: Concepts, strategies, and case studies* (3rd ed.). McGraw-Hill/Irwin.
27. **Syntetos, A. A., & Boylan, J. E.** (2005). The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), 303–314.
<https://doi.org/10.1016/j.ijforecast.2004.10.001>
28. **Ünal, Ö. A., Erkeyman, B., & Usanmaz, B.** (2023). Applications of artificial intelligence in inventory management: A systematic review. *Archives of Computational Methods in Engineering*.
29. **Zipkin, P. H.** (2000). *Foundations of inventory management*. McGraw-Hill/Irwin.

APÉNDICES



```
# 02) Leer todos los .xlsx (No calendariza, no rellena ceros)
def read_xlsx(path: Path) -> pd.DataFrame:
    # Lee 3 hojas; si tu archivo usa varias, cambia sheet_name="Export" o como corresponda
    t = pd.read_excel(path, sheet_name=0, engine="openpyxl", dtype={"Producto": "string"})
    t.columns = [c.strip() for c in t.columns]

    # quedarse solo con las 3 columnas (renombres tolerantes)
    ren = {c: "Fecha" for c in t.columns if c.lower().strip()=="fecha"}
    ren |= {c: "Producto" for c in t.columns if c.lower().strip()=="producto"}
    ren |= {c: "Demanda (kg)" for c in t.columns if c.lower().replace("_", " ").replace(" ", "").strip() in {"demanda (kg)", "demanda kg", "demanda"}}
    t = t.rename(columns=ren)[["Fecha", "Producto", "Demanda (kg)"]]

    # tipos
    if not np.issubdtype(t["Fecha"].dtype, np.datetime64):
        t["Fecha"] = pd.to_datetime(t["Fecha"], errors="coerce") # Excel ya viene ok, esto es por si acaso
    t["Demanda (kg)"] = pd.to_numeric(t["Demanda (kg)"], errors="coerce")
    t["Producto"] = t["Producto"].astype("string").str.strip()

    return t

files = sorted([p for p in DATA_DIR.glob("*.xlsx") if p.is_file()])
assert files, f"No hay .xlsx en {DATA_DIR}"
df = pd.concat([read_xlsx(f) for f in files], ignore_index=True).sort_values(["Producto", "DATE_COL"])
print(f"Filas: {len(df):,} | Productos: {df['Producto'].nunique():,}")

# 03) Chequesos
n_hat = #(DATE COL) len(f) em(f)
```

Requirement already satisfied: openpyxl in c:\users\asus\appdata\local\programs\python\python311\lib\site-packages (3.1.5)
Requirement already satisfied: et-xmlfile in c:\users\asus\appdata\local\programs\python\python311\lib\site-packages (from openpyxl) (2.0.0)
Note: you may need to restart the kernel to use updated packages.
Filas: 139,200 | Productos: 100

Captura de pantalla de código de feature engineering utilizado

```

3. Tuning (TimeSeriesSplit en TRAIN) + gráfico del tuning

# === 3) Tuning con validación temporal (solo TRAIN) ===
from sklearn.metrics import make_scorer

# scorer de RMSE (minimizar)
rmse_scorer = make_scorer(lambda yt, yh: np.sqrt(mean_squared_error(yt, yh)), greater_is_better=False)

tscv = TimeSeriesSplit(n_splits=5)
rf = RandomForestRegressor(random_state=42, n_jobs=-1)

param_dist = {
    "n_estimators": [300, 500, 800],
    "max_depth": [None, 14, 18, 22],
    "min_samples_leaf": [2, 3, 5],
    "max_features": [0.5, 0.7, 1.0]
}

search = RandomizedSearchCV(
    rf, param_distributions=param_dist, n_iter=20,
    scoring=rmse_scorer, cv=tscv, random_state=42, n_jobs=-1, verbose=0, refit=True
)

search.fit(X_tr, y_tr)
best_params = search.best_params_

# --- Gráfico compacto del tuning ---
cv = pd.DataFrame(search.cv_results_)
cv["rmse"] = -cv["mean_test_score"]
plt.figure(figsize=(6,4))
plt.scatter(range(len(cv)), cv["rmse"], s=18, alpha=0.7)
plt.axhline(cv["rmse"].min(), color="tab:red", ls="--", lw=1)
plt.title("Tuning RF (TimeSeriesSplit sobre TRAIN) | RMSE promedio CV")
plt.ylabel("RMSE (menor mejor)"); plt.xlabel("Configuración (orden aleatorio)")
plt.tight_layout(); plt.show()

```

Captura de pantalla de fragmento de código de tuning de modelo Random Forest

```

# === 4) Entrenamiento final (TRAIN+VALID) y evaluación en TEST ===
X_trva = pd.concat([X_tr, X_va], axis=0, ignore_index=True)
y_trva = np.concatenate([y_tr, y_va], axis=0)

mlp_final = Pipeline(steps=[("prep", preproc), ("mlp", MLPRegressor(
    **{k.split("_")[1]: v for k,v in best_params.items() if k.startswith("mlp_")}
, max_iter=2000, random_state=42, early_stopping=True, n_iter_no_change=25,
validation_fraction=0.15, shuffle=False
))])

mlp_final.fit(X_trva, y_trva)
pred_te = mlp_final.predict(X_te)

print("== TEST ==")
print(f"MLP FINAL | RMSE={rmse(y_te,pred_te):.3f} | MAE={mean_absolute_error(y_te,pred_te):.3f} | sMAPE={smape(y_te,pred_te):.2f}%")

== TEST ==
MLP FINAL | RMSE=33.026 | MAE=10.470 | sMAPE=42.81%

# === 5) Gráficos clave ===
# Global (promedio por día)
g = (test[[DATE_COL, TARGET]].assign(yhat=pred_te)
    .groupby([DATE_COL, as_index=False]).mean(numeric_only=True))
plt.figure(figsize=(8,4))
plt.plot(g[DATE_COL], g[TARGET], label="Demanda (prom. día)")
plt.plot(g[DATE_COL], g[yhat], label="MLP (prom. día)")
plt.legend(); plt.title("TEST | Promedio diario (Global)")
plt.tight_layout(); plt.show()

# Top-2 SKUs por volumen
top_sku = (test.groupby([PROD_COL][TARGET]).sum().sort_values(ascending=False).head(2).index)
for sku in top_sku:

```

Captura de pantalla de entrenamiento de modelo MLP implementado