

**Aplicación de Prophet en la predicción de ventas en el sector retail para inteligencia de negocios**

Estefania Diaz Morera

Tutor

Felipe Alexander Pipicano Guzman

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería - ECBTI

Especialización Ciencia de Datos y Analítica

2026

---

Nombre Director de Trabajo de Grado

---

Jurado

---

Jurado

### **Dedicatoria**

A Dios, porque incluso en la frustración me fue revelando el camino, y hoy comprendo que este proceso fue por y para mí. A mi madre, por su apoyo constante, su esfuerzo silencioso y por darme el espacio y la confianza para dedicarme plenamente a este objetivo. A mi familia, que en distintos momentos ha sido un respaldo cuando más se ha necesitado. Y a mí misma, por la disciplina, la perseverancia y la capacidad de llegar más lejos de lo que imaginé.

## Resumen

Esta monografía presenta una revisión profunda de la aplicación del modelo Prophet en la predicción de ventas dentro del sector retail, enfocado en su utilidad como herramienta estratégica para Inteligencia de Negocios (BI). El estudio se justifica en la necesidad de soluciones de forecasting de alto impacto y baja barrera técnica.

Inicialmente, Prophet es examinado y comparado con el algoritmo de Machine Learning XGBoost y el modelo clásico ARIMA, evaluando tres criterios funcionales: precisión, interpretabilidad y facilidad de integración en entornos de BI, para establecer su posición estratégica. Posteriormente, el estudio se centra en validar la utilidad de Prophet a través de la revisión de casos de éxito y estudios de aplicación, destacando su efectividad para impulsar la optimización de inventarios y la planificación comercial. Finalmente, se desarrolla una propuesta metodológica concisa para su implementación en un contexto de retail, sirviendo como guía para la adopción ágil de la herramienta en sistemas de Business Intelligence.

Se concluye que Prophet facilita la toma de decisiones gerenciales gracias a su explicabilidad nativa, que permite a los usuarios de negocio comprender y confiar en los pronósticos sin requerir un conocimiento estadístico avanzado. Su diseño modular y bajo requerimiento técnico lo posicionan como la herramienta más eficiente para la adopción masiva y el despliegue ágil de soluciones de predicción en el retail.

**Palabras claves:** Ventas, Retail, Prophet, XGBoost, ARIMA, Interpretabilidad

## Abstract

This monograph presents a deep review of the application of the Prophet model in sales prediction within the retail sector, focusing on its utility as a strategic tool for Business Intelligence (BI). The study is justified by the need for forecasting solutions that offer high impact with a low technical barrier to entry.

Initially, Prophet is examined and compared against the Machine Learning algorithm XGBoost and the classic ARIMA model, evaluating three functional criteria: accuracy, interpretability, and ease of integration into BI environments, to establish its strategic position. Subsequently, the study focuses on validating Prophet's utility through the review of success cases and application studies, highlighting its effectiveness in driving inventory optimization and commercial planning. Finally, a concise methodological proposal for its implementation in a retail context is developed, serving as a guide for the agile adoption of the tool within Business Intelligence systems.

It is concluded that Prophet facilitates managerial decision-making thanks to its native explainability, which allows business users to understand and trust forecasts without requiring advanced statistical knowledge. Its modular design and low technical requirements position it as the most efficient tool for the massive adoption and agile deployment of prediction solutions in retail.

**Keywords:** Sales, Retail, Prophet, XGBoost, ARIMA, Interpretability

## Tabla de Contenido

Introducción .....	12
Descripción del Problema .....	15
Justificación .....	18
Objetivos .....	22
Objetivo General .....	22
Objetivos Específicos.....	22
Marco de Referencia .....	23
Marco Contextual.....	23
Contexto Global del Sector Retail.....	23
Contexto Regional Latinoamericano del Sector Retail.....	25
Marco Teórico.....	27
Fundamentos Conceptuales de Forecasting en Series Temporales.....	27
Arquitectura y Fundamentos Técnicos del Modelo Prophet.....	28
Prophet en Perspectiva Comparativa: ARIMA y XGBoost.....	29
Aplicaciones de Prophet en Retail y Evaluación de Desempeño.....	30
Consideraciones de Implementación y Limitaciones.....	31
Marco Conceptual.....	32
Forecasting y Conceptos Fundamentales .....	32
Modelos y Algoritmos Predictivos.....	33
Métricas de Evaluación .....	34
Inteligencia de Negocios y Aplicaciones .....	35
Conceptos Técnicos Especializados.....	36

Metodología .....	38
Criterios de Selección y Exclusión .....	39
Análisis y Síntesis de la Información.....	39
Revisar y Sistematizar la Literatura Científica Reciente Sobre el Uso del Modelo Prophet en la Predicción de Ventas en el Sector Retail .....	41
Caracterización Sistemática de Datasets Documentados.....	41
Taxonomía de Sectores y Productos Analizados .....	42
Sistematización de Horizontes Predictivos Documentados .....	42
Métricas de Evaluación por Contexto de Aplicación .....	43
Comparar las Capacidades de Prophet Frente al Modelo Clásico ARIMA y Moderno XGBoost, Analizando Precisión, Interpretabilidad y Facilidad de Integración en Entornos de BI.....	44
Introducción y Contextualización .....	44
Resultados Comparativos de Precisión: Contexto Metodológico y Hallazgos.....	45
Contexto de Evaluación y Metodología Experimental .....	45
Jerarquía de Rendimiento y Hallazgos de Precisión .....	47
El Contrapunto Académico y la Dependencia del Conjunto de Datos .....	48
Interpretabilidad y Explicabilidad.....	49
Facilidad de Integración y Despliegue en BI.....	52
Identificar los Factores Críticos de Éxito y Limitaciones en la Implementación de Prophet en Retail, Incluyendo Calidad de Datos, Estacionalidades Múltiples, Promociones y Quiebres de Inventario .....	54
Factores Críticos de Éxito.....	55
Calidad y Disponibilidad de Datos Históricos .....	55

Capacidad de Modelado: Estacionalidades y Variables Exógenas .....	57
Interpretabilidad y Facilidad de Integración en BI .....	60
Limitaciones y Desafíos Operativos .....	63
Limitaciones con Características de Datos .....	63
Factores Externos No Capturados .....	65
Necesidad de Modelos Híbridos o Complementarios .....	66
Síntesis: Condiciones Óptimas de Aplicación de Prophet en Retail.....	69
Perfil de Aplicabilidad Óptima .....	70
Escenarios Donde Prophet Enfrenta Limitaciones Críticas .....	71
Estrategias Pragmáticas de Implementación .....	72
Contextualizar la Aplicabilidad de Prophet en el Mercado Colombiano, Considerando Patrones de Consumo Asociados a Quincenas, Festivos Nacionales y Temporadas Comerciales .....	74
Características Estructurales del Retail Colombiano .....	74
Patrones de Consumo Asociados a Quincenas y Festividades Colombianas .....	75
Desafíos Específicos para Forecasting en Colombia .....	76
Oportunidades de Prophet en el Contexto Colombiano .....	78
Proponer Lineamientos Prácticos para la Adopción de Prophet en Sistemas de Inteligencia de Negocios Orientados a la Optimización de Inventarios y la Toma de Decisiones Estratégicas....	81
Prerrequisitos para la Adopción de Prophet en Retail .....	81
Marco de Decisión para Selección de Enfoque Predictivo .....	84
Lineamientos Operativos de Implementación .....	86
Conclusiones .....	91
Recomendaciones .....	93

Referencias Bibliográficas .....94

**Lista de Tablas**

<b>Tabla 1</b> <i>Métricas de Error de Predicción y su Relevancia Operacional en Retail</i> .....	46
<b>Tabla 2</b> <i>Comparativa de Interpretabilidad y Recursos de Explicación</i> .....	51
<b>Tabla 3</b> <i>Prerrequisitos para Adopción de Prophet en Retail</i> .....	82
<b>Tabla 4</b> <i>Marco de Decisión para Selección de Enfoque Predictivo</i> .....	85
<b>Tabla 5</b> <i>Lineamientos Operativos para Implementación de Prophet</i> .....	88

**Lista de Figuras**

<b>Figura 1</b> <i>Diagrama de Flujo del Proceso de Selección Según Protocolo PRISMA</i> .....	38
--	----

## Introducción

El sector retail contemporáneo experimenta una transformación estructural profunda impulsada por la digitalización acelerada y la adopción de tecnologías analíticas avanzadas. Fildes et al. (2022) comercio minorista ha experimentado un cambio desde la intuición hacia la toma de decisiones basada en datos que puede capitalizar esto", evidenciando la evolución hacia paradigmas analíticos sofisticados. Esta metamorfosis adquiere particular relevancia considerando que, según Rios y Vera (2023), únicamente en Estados Unidos el sector retail representa \$3.9 trillones del PIB anual y sustenta uno de cada cuatro empleos estadounidenses, subrayando su importancia estratégica en las economías contemporáneas.

Nasseri et al. (2023) caracterizan el entorno retail por "cambios rápidos al ambiente de negocios, horizontes de planificación más cortos, márgenes de ganancia menores y problemas de servicio al cliente", intensificando los desafíos operacionales. En este contexto, Taylor y Letham (2018) desarrollaron Prophet específicamente para "forecasting at scale", posicionándolo como una herramienta diseñada para abordar los requerimientos masivos de predicción que caracterizan al retail moderno. La efectividad de Prophet se manifiesta en aplicaciones documentadas donde alcanza un MAPE de 22.62% comparado con 28.98% de SARIMA en contextos que incorporan efectos de feriados (Ensafi et al., 2022), evidenciando su capacidad técnica diferenciada.

A pesar del potencial demostrado por Prophet en aplicaciones internacionales, persiste una brecha crítica en la consolidación de evidencia sistemática, particularmente en contextos latinoamericanos donde las dinámicas de mercado presentan características distintivas. Žunić et al. (2020) identifican explícitamente la necesidad de "cerrar la brecha hacia la aplicación del pronóstico de series temporales en escenarios del mundo real en la industria minorista",

reconociendo las limitaciones de la investigación actual para abordar implementaciones prácticas. Esta problemática se intensifica en América Latina, donde Olavarrieta y Villena (2014) documentan que "la producción de investigación empresarial en América Latina es muy escasa y proporcionalmente baja comparada con investigación en otras ciencias en la región", evidenciando un vacío académico regional significativo. Paradójicamente, Wellens et al. (2024) confirman que "a pesar de ser consistentemente superados por machine learning en competencias de pronóstico, las técnicas estadísticas simples permanecen como estándar en retail", indicando una desconexión entre capacidades técnicas disponibles y adopción práctica organizacional. Page et al. (2021) establecen que las "revisiones sistemáticas son útiles ya que pueden proporcionar una síntesis del estado del conocimiento en un área determinada, identificar futuras prioridades de investigación y generar teorías sobre cómo ocurren fenómenos de interés", justificando metodológicamente la necesidad de consolidación académica rigurosa.

Esta monografía contribuye específicamente al análisis sistemático de la aplicabilidad del modelo Prophet en predicción de ventas retail dentro del contexto de inteligencia de negocios, con énfasis particular en factores de implementación práctica y adaptación a realidades latinoamericanas. Atanda et al. (2024) enfatizan que "el pronóstico de ventas proporciona valor a toda la organización", abarcando desde planificación financiera hasta estrategias de cadena de suministro, estableciendo la relevancia transversal del tema investigado. La investigación se justifica en la necesidad identificada por Praveena y Prasanna Devi (2024) quienes señalan que "la información de sistemas de pronóstico de demanda es crucial para procesos de toma de decisiones de gestión de inventarios en retail", especialmente considerando que muchas tiendas han "incrementado su inversión en tecnología de predicción de demanda en años recientes". Ali y Nakti (2023) corroboran la relevancia práctica al buscar "crear una herramienta de predicción

confiable y genérica para negocios que ayude en la toma de decisiones de CEOs", estableciendo el vínculo directo entre capacidades técnicas de pronóstico y valor estratégico organizacional.

La estructura de esta monografía se desarrolla progresivamente a través de cinco objetivos específicos que abordan dimensiones complementarias del problema investigado. Inicialmente, se sistematiza la literatura científica reciente sobre aplicaciones de Prophet en retail, identificando sectores, horizontes temporales y métricas de evaluación predominantes. Posteriormente, se establece una comparación rigurosa entre Prophet, ARIMA y XGBoost, evaluando precisión predictiva, interpretabilidad y facilidad de integración en entornos de inteligencia de negocios. La investigación continúa con la identificación de factores críticos de éxito y limitaciones operacionales en implementación de Prophet, considerando calidad de datos, estacionalidades múltiples y efectos promocionales. A continuación, se contextualiza la aplicabilidad al mercado colombiano, reconociendo patrones específicos como quincenas, festividades nacionales y temporadas comerciales. Finalmente, se proponen lineamientos prácticos para adopción de Prophet en sistemas de inteligencia de negocios orientados a optimización de inventarios y fortalecimiento de capacidades de toma de decisiones estratégicas en el sector retail.

## Descripción del Problema

El sector retail constituye un pilar fundamental de las economías contemporáneas, generando impactos significativos tanto en indicadores macroeconómicos como en dinámicas de empleo. Rios y Vera (2023) documentan que únicamente en Estados Unidos, este sector representa \$3.9 trillones del PIB anual y sustenta uno de cada cuatro empleos estadounidenses, evidenciando su relevancia estratégica. En el contexto latinoamericano, D'Andrea (2010) caracteriza el retail regional por la coexistencia singular entre modernidad y tradición, donde grandes cadenas internacionales conviven con comercios tradicionales e informales, configurando mercados fragmentados condicionados por factores como urbanización heterogénea, informalidad persistente y diversidad en patrones de consumo. Esta complejidad estructural intensifica los desafíos operacionales, particularmente en la gestión predictiva de la demanda. Fildes et al. (2022) enfatizan categóricamente que "la capacidad de pronosticar la demanda de cada artículo en cada tienda o centro de distribución con la mayor precisión posible es crítica para la supervivencia y el crecimiento de una cadena minorista", estableciendo el pronóstico como competencia estratégica diferenciadora.

Los errores en pronóstico de ventas generan consecuencias operacionales y financieras inmediatas que comprometen tanto la rentabilidad como la satisfacción del cliente. Fildes et al. (2022) establecen que "los errores de pronóstico conducen directamente a un servicio más deficiente y mayores costos", especificando que las decisiones de pedidos deben equilibrar niveles de inventario que eviten tanto costos elevados de almacenamiento como desabastecimientos que resulten en ventas perdidas. La magnitud de estos impactos se ilustra mediante casos documentados: un estudio de restaurante peruano reporta costos de oportunidad por 23 compras improvisadas mensuales a proveedores minoristas debido a pronósticos

empíricos con precisión inferior al 50%, mientras que episodios de sobreabastecimiento resultaron en desecho del 40% de insumos excedentes por caducidad (Chiroque, 2025). Fredén y Larsson (2020) cuantifican el potencial de mejora al demostrar que una reducción de 0.7-1.0 en el error absoluto medio representa una disminución de 25 unidades desperdiciadas o ventas perdidas por día para cada tienda. Praveena y Prasanna Devi (2024) conceptualizan este dilema como la tensión fundamental entre "Out-of-Stock" y "Overstock", donde ambas situaciones erosionan la rentabilidad mediante mecanismos diferenciados pero igualmente perjudiciales.

A pesar de los avances metodológicos en predicción de series temporales, persisten brechas críticas de conocimiento que limitan la implementación efectiva de soluciones analíticas avanzadas en contextos retail. Žunić et al. (2020) identifican explícitamente la necesidad de "cerrar la brecha hacia la aplicación del pronóstico de series temporales en escenarios del mundo real en la industria minorista", reconociendo que los datos reales de ventas presentan desafíos únicos como alta no estacionaridad, patrones irregulares y efectos complejos de eventos promocionales. En el ámbito latinoamericano, esta problemática se intensifica por la escasez de investigación regional. Gimeno-Arias et al. (2024) señalan que "el vínculo entre comercio electrónico y rendimiento corporativo está aún subexplorado en PYMES, especialmente entre empresas de América Latina", mientras que Olavarrieta y Villena (2014) documentan que "la producción de investigación empresarial en América Latina es muy escasa y proporcionalmente baja comparada con investigación en otras ciencias en la región". Adicionalmente, Mirza et al. (2025) identifican "una pregunta de investigación fundamental que no ha sido completamente abordada respecto al potencial de sistemas de BI impulsados por IA para transformar datos de clientes en herramientas estratégicas".

La convergencia de estas brechas justifica una investigación sistemática sobre la aplicabilidad del modelo Prophet en contextos de inteligencia de negocios para retail latinoamericano. Taylor y Letham (2018) desarrollaron Prophet específicamente para "forecasting at scale", pero la literatura carece de orientación práctica sobre implementación organizacional en economías emergentes con recursos tecnológicos heterogéneos. Wellens et al. (2024) confirman que "a pesar de ser consistentemente superados por machine learning en competencias de pronóstico, las técnicas estadísticas simples permanecen como estándar en retail", atribuyendo esta paradoja a barreras de implementación, complejidad metodológica y requisitos computacionales que "pueden prevenir a retailers 'tradicionales' de poner estas técnicas de ML en producción". Atanda et al. (2024) corroboran que el despliegue de modelos complejos "exige mayor inversión en infraestructura MLOps", evidenciando barreras que afectan desproporcionadamente a economías emergentes. Por tanto, surge la pregunta de investigación: ¿Cómo puede el modelo Prophet optimizar la predicción de ventas en el sector retail dentro del contexto de inteligencia de negocios en Latinoamérica, considerando factores de implementación práctica, calidad de datos y integración tecnológica?

## Justificación

El sector retail constituye un motor fundamental de las economías contemporáneas, consolidando su posición como pilar estratégico tanto en indicadores macroeconómicos como en la configuración de dinámicas socioeconómicas globales. Rios y Vera (2023) documentan que únicamente en Estados Unidos el sector retail representa \$3.9 trillones del PIB anual y sustenta uno de cada cuatro empleos estadounidenses, evidenciando su relevancia estratégica para la estabilidad económica nacional. Esta magnitud trasciende la dimensión puramente transaccional, estableciendo al retail como articulador fundamental de cadenas de valor extensas que conectan producción, distribución y consumo final. Bălan (2021) caracteriza el rol multifacético de los retailers como determinante en la orientación de consumidores hacia patrones sostenibles, requiriendo que "acompañen a consumidores durante las siguientes etapas: concienciación sobre la necesidad de consumo sostenible, desarrollo de opiniones favorables, expresión de preferencias por productos sostenibles, comportamiento de compra sostenible y reducción de residuos", estableciendo la función social ampliada del sector. Mohamad et al. (2023) corroboran que "el análisis de tendencias de ventas puede mejorar la eficiencia de una empresa en términos de gestión de inventarios, selección de productos y administración de ventas, conduciendo a mayores ganancias y costos reducidos", fundamentando económicamente la relevancia de capacidades analíticas avanzadas en retail.

La precisión en pronóstico de ventas emerge como competencia estratégica crítica ante un entorno caracterizado por volatilidad creciente, márgenes operacionales comprimidos y expectativas de servicio al cliente intensificadas. Nasser et al. (2023) caracterizan el entorno retail contemporáneo por "cambios rápidos al ambiente de negocios, horizontes de planificación más cortos, márgenes de ganancia menores y problemas de servicio al cliente", intensificando los

desafíos predictivos tradicionales. Esta complejidad operacional se manifiesta particularmente en la gestión de inventarios, donde errores de pronóstico generan consecuencias financieras directas y sistemáticas. Praveena y Prasanna Devi (2024) establecen que "para muchos procesos de toma de decisiones de gestión de inventarios retail, la información de sistemas de pronóstico de demanda es crucial", especificando que las deficiencias predictivas comprometen tanto disponibilidad de productos como eficiencia de capital de trabajo. Bell (2000) documenta que los desabastecimientos no solo limitan ventas efectivas sino que distorsionan la exactitud de pronósticos subsecuentes al crear sesgos en datos históricos, evidenciando efectos en cascada que amplifican consecuencias operacionales. Naskinova et al. (2024) cuantifican este impacto señalando que "el pronóstico de demanda se aplica igualmente a manufactura, logística, gestión de cadena de suministro, planificación de capacidad, programación de producción y optimización de cadena de suministro", estableciendo la transversalidad organizacional del problema.

En este contexto desafiante, Prophet se posiciona como solución tecnológica diferenciada que aborda limitaciones fundamentales de métodos tradicionales mientras mantiene accesibilidad operacional para organizaciones con recursos analíticos heterogéneos. Taylor y Letham (2018) diseñaron Prophet específicamente para "forecasting at scale", incorporando capacidades nativas para gestionar múltiples estacionalidades, eventos especiales y cambios estructurales sin requerir estacionaridad en series temporales. Las ventajas técnicas distintivas incluyen robustez ante datos faltantes, facilidad de configuración sin expertise estadística avanzada y interpretabilidad nativa que facilita adopción organizacional. Zhao y Zhang (2020) demuestran que modelos combinados Prophet-SARIMA "pueden capturar simultáneamente características de periodicidad y efectos de feriados", mientras que su implementación "puede proporcionar una base importante

para que el e-commerce complemente pedidos científicamente". Panay et al. (2021) corroboran la utilidad práctica documentando que su aproximación interpretable "produce valor de salida para tres indicadores de rendimiento junto con intervalo de confianza", estableciendo que "el rendimiento obtenido es comparable a los mejores modelos de regresión existentes reportados en literatura" y "actualmente está ejecutando una implementación del algoritmo para ofrecer servicio de predicción a sus clientes retail".

La relevancia de esta investigación se intensifica considerando las características distintivas del mercado latinoamericano, donde la coexistencia de modernidad y tradición configura desafíos únicos para implementación de tecnologías analíticas avanzadas. D'Andrea (2010) documenta que el crecimiento de la clase media emergente genera relevancia estratégica que "no proviene solo de su demanda actual de alimentos y comestibles sino especialmente de su potencial futuro latente", cuantificando que "este segmento de consumidores representará casi todo el gasto incremental en alimentos, bebidas y salud, belleza y cuidado personal en México durante los próximos 5 años, representando más de US\$18.5 billones". Gimeno-Arias et al. (2024) identifican que "el vínculo entre e-commerce y rendimiento corporativo está aún subexplorado en PYMES, especialmente entre empresas de América Latina", evidenciando brechas específicas de conocimiento regional. Esta contextualización adquiere particular relevancia considerando que Olavarrieta y Villena (2014) documentan que "la producción de investigación empresarial en América Latina es muy escasa y proporcionalmente baja comparada con investigación en otras ciencias en la región", estableciendo la necesidad crítica de consolidación académica contextualizada.

La contribución esperada de esta monografía se articula en múltiples dimensiones que responden directamente a brechas identificadas tanto en literatura académica como en

necesidades prácticas organizacionales. AbdElminaam et al. (2024) establecen que la exploración de "modelos de machine learning y deep learning, incluyendo Linear Regression, AdaBoost, Random Forest, XGBoost, SARIMA, ARIMA y Prophet" para predicción de ventas "demuestra la efectividad de modelos de machine learning en predicción de ventas y ofrece insights valiosos para toma de decisiones retail", justificando la necesidad de análisis comparativo sistemático. Phalachandra et al. (2023) plantean explícitamente "la pregunta que surge es si el algoritmo Prophet puede producir pronósticos con mayor precisión comparado con modelos como LSTM que han estado en uso por décadas", evidenciando la necesidad de evaluación rigurosa de capacidades predictivas. Sunaina et al. (2025) corroboran que "integrar gestión de inventarios con análisis de ventas y asociaciones de productos destaca cómo la toma de decisiones basada en datos puede transformar operaciones retail, particularmente para negocios operando en mercados diversos y competitivos". Por tanto, esta investigación se justifica en la consolidación sistemática de evidencia dispersa sobre aplicaciones de Prophet en retail, proporcionando síntesis crítica que compare desempeño técnico, identifique factores de éxito organizacional y contextualice hallazgos para realidades latinoamericanas, transformando conocimiento académico fragmentado en orientación práctica que facilite adopción estratégica de capacidades analíticas avanzadas para optimización de gestión de inventarios, reducción de costos operacionales y fortalecimiento de competitividad regional.

## Objetivos

### Objetivo General

Analizar las aplicaciones y beneficios del modelo Prophet en la predicción de ventas en el sector retail, dentro del contexto de la inteligencia de negocios, a partir de la revisión y síntesis de estudios y artículos científicos.

### Objetivos Específicos

Revisar y sistematizar la literatura científica reciente sobre el uso de Prophet en la predicción de ventas en retail, identificando sectores, horizontes de aplicación y métricas de evaluación.

Comparar las capacidades de Prophet frente al modelo clásico ARIMA y moderno XGBoost, analizando precisión, interpretabilidad y facilidad de integración en entornos de BI.

Identificar los factores críticos de éxito y limitaciones en la implementación de Prophet en retail, incluyendo calidad de datos, estacionalidades múltiples, promociones y quiebres de inventario.

Contextualizar la aplicabilidad de Prophet en el mercado colombiano, considerando patrones de consumo asociados a quincenas, festividades nacionales y temporadas comerciales.

Proponer lineamientos prácticos para la adopción de Prophet en sistemas de inteligencia de negocios orientados a la optimización de inventarios y la toma de decisiones estratégicas.

## Marco de Referencia

### Marco Contextual

El sector retail, también conocido como comercio minorista, se define como la venta directa de productos a consumidores finales. Rios y Vera (2023) muestran la importancia de este sector: solo en Estados Unidos representa \$3.9 trillones del PIB y uno de cada cuatro empleos. Esta cifra demuestra que el retail es fundamental para la economía de cualquier país.

El pronóstico de ventas es clave para el éxito de las empresas retail. Mohamad et al. (2023) explican que "el análisis de tendencias de ventas puede mejorar la eficiencia de una empresa en términos de gestión de inventarios, selección de productos y administración de ventas, conduciendo a mayores ganancias y costos reducidos". En términos simples, predecir las ventas correctamente ayuda a las empresas a tener los productos correctos en el momento adecuado, evitando tanto la falta de stock como el exceso de inventario.

Praveena y Prasanna Devi (2024) confirman que "para muchos procesos de toma de decisiones de gestión de inventarios retail, la información de sistemas de pronóstico de demanda es crucial". Cuando las empresas no pueden predecir bien sus ventas, enfrentan dos problemas principales: quedarse sin productos cuando los clientes los quieren, o tener demasiados productos que no se venden.

### *Contexto Global del Sector Retail*

El sector retail global experimenta una transformación estructural impulsada por la globalización acelerada y la adopción de tecnologías digitales avanzadas. Negre et al. (2024) documentan que las empresas operan en mercados crecientemente globalizados, donde el tráfico marítimo de contenedores se ha cuadruplicado entre 2000 y 2020, evidenciando la intensificación del comercio internacional. Esta dinámica requiere que las organizaciones

comprendan la evolución del mercado para garantizar una gestión eficiente de recursos y mantener desarrollo económico sostenible.

La omnicanalidad ha redefinido fundamentalmente las operaciones retail contemporáneas. Mou et al. (2018) establecen que las tiendas físicas ya no representan únicamente espacios de compra offline, sino que evolucionan hacia centros de interacción multicanal. Complementariamente, Dankorpo (2024) documenta que los negocios retail se expanden continuamente mediante diversos canales donde los clientes acceden a productos más allá de canales offline tradicionales, incluyendo sitios web propios, plataformas de e-commerce y redes sociales. Esta evolución ha llevado a que algunas tiendas se conviertan esencialmente en centros de distribución miniaturizados para cumplimiento de pedidos online, proporcionando servicios de click-and-collect y entrega domiciliaria (Mou, Robb, & DeHoratius, 2018).

La adopción de Big Data y analytics ha transformado las capacidades de pronóstico en cadenas de suministro retail. Syntetos et al. (2016) evidencian que la tendencia hacia Big Data, facilitada por nuevos desarrollos en tecnología de bases de datos, mantiene implicaciones importantes para el forecasting, permitiendo almacenar datos en granularidades progresivamente finas donde anteriormente los retailers conservaban ventas agregadas semanalmente por SKU y tienda, actualmente mantienen datos significativamente más desagregados a nivel diario mínimo. La integración de machine learning ha demostrado ventajas significativas en demand forecasting, siendo adoptado por diversas industrias para lograr efectividad de costos, optimizar asignación de recursos y satisfacer demanda del consumidor (Mehmood, Broderick, Davies, Bashir, & Rabie, 2024).

La evolución metodológica en forecasting refleja esta transformación tecnológica. Zhao y Zhang (2020) establecen que los métodos actuales de predicción de volúmenes de venta incluyen

principalmente modelos tradicionales de series temporales como ARIMA, modelos de redes neuronales y modelos de predicción combinada. No obstante, Ali y Nakti (2023) documentan que metodologías basadas en deep learning han sido propuestas para abordar problemas de forecasting de series temporales, donde machine learning ha demostrado ser particularmente ventajoso en este dominio. La competencia intensificada entre retailers establecidos y nuevos entrantes, incluyendo jugadores puramente online y competidores geográficos, ha amplificado la necesidad de capacidades predictivas sofisticadas (Syntetos, Babai, Boylan, Kolassa, & Nikolopoulos, 2016).

### ***Contexto Regional Latinoamericano del Sector Retail***

El retail latinoamericano se caracteriza por una distintiva coexistencia entre modernidad y tradición que define su estructura de mercado fragmentada. D'Andrea (2010) documenta que los "rugientes noventa" proporcionaron un escenario perfecto para modernizar el sector retail de bienes de consumo masivo en América Latina, donde políticas macroeconómicas sólidas, regulaciones favorables, estabilización después de décadas de inflación y perspectivas favorables de comercio e inversión para mercados emergentes se combinaron para crear condiciones apropiadas para inversiones agresivas en retail tanto de cadenas multinacionales como locales. Esta transformación generó un mercado donde el vientre del mercado representa actualmente alrededor del 60% de consumidores latinoamericanos, constituyendo aproximadamente 320 millones de consumidores objetivo en la región.

El crecimiento del comercio electrónico latinoamericano evidencia la aceleración digital regional. D'Andrea (2010) reporta que en 2005 las ventas online en América Latina superaron US\$4.3 mil millones, mostrando crecimiento anual significativo especialmente en Venezuela (185%), México (104%), Chile (100%) y Brasil (43%). Esta evolución digital ha intensificado la

necesidad de adoptar herramientas tecnológicas avanzadas para gestión comercial, donde las empresas latinoamericanas han comenzado a incorporar analítica de datos y aprendizaje automatizado para fortalecer estrategias de gestión (Olavarrieta & Villena, 2014).

La fragmentación del mercado latinoamericano presenta características únicas para implementación de soluciones predictivas. Astarloa et al. (2021) documentan que las ventas B2C de e-commerce sugieren que la participación de LAC en e-commerce global permanece marginal, alcanzando US\$47 mil millones en 2015 con incremento del 24% desde 2014, representando únicamente 2% del mercado B2C global para LAC, significativamente inferior a su participación en comercio de mercancías global (6%). Adicionalmente, la penetración de e-commerce permaneció considerablemente inferior al promedio OCDE antes de la pandemia, donde el promedio de usuarios de internet comprando online en LAC alcanzó 15.5% en 2017-2018, menos de un cuarto de la penetración promedio en OCDE.

Las limitaciones en capacidades de investigación e innovación regional impactan el desarrollo de soluciones tecnológicas locales. Olavarrieta y Villena (2014) evidencian que América Latina y el Caribe se posiciona significativamente inferior en indicadores de investigación, alcanzando 500 investigadores por millón de habitantes, siendo Argentina con aproximadamente 1100 investigadores por millón y Brasil con 670 los líderes regionales. Esta situación se refleja en la baja producción de patentes, donde América Latina y el Caribe registra números realmente bajos comparado con otros grupos de países, alcanzando únicamente cerca de 4000 patentes en 2010, siguiendo tendencia decreciente del período 2005-2008 cuando promediaba más de 6000 patentes.

La aplicación de técnicas predictivas en contextos regionales específicos demuestra adaptabilidad de modelos avanzados a particularidades locales. Žunić et al. (2021) documentan

implementaciones en una de las empresas de distribución más grandes de Bosnia y Herzegovina, utilizando información sobre feriados locales. Panay et al. (2021) extienden esta evidencia mediante datos retail de Follow Up, empresa de experiencia del cliente basada en Santiago, Chile, con cámaras instaladas en más de 3000 tiendas en varios países, utilizando específicamente datos de tiendas ubicadas en Chile, Colombia y Perú para desarrollo y prueba de modelos predictivos. Esta evidencia sugiere que la adaptación de herramientas predictivas a contextos culturales y operacionales específicos representa una oportunidad significativa para mejorar la efectividad de soluciones tecnológicas en mercados latinoamericanos.

## **Marco Teórico**

### ***Fundamentos Conceptuales de Forecasting en Series Temporales***

Las series temporales son conjuntos de datos organizados cronológicamente donde el orden temporal contiene información valiosa para identificar patrones (Fredén & Larsson, 2020). Asati (2022) las define como secuencias de datos capturados en intervalos regulares que preservan dependencias temporales entre observaciones consecutivas. Esta característica permite que valores pasados funcionen como predictores de observaciones futuras, principio que sustenta los modelos de pronóstico (Fredén & Larsson, 2020).

Para que los métodos estadísticos tradicionales funcionen correctamente, las series temporales deben cumplir con una propiedad llamada estacionaridad. Asati (2022) explica que esto significa que la media, varianza y estructura de correlaciones permanecen constantes en el tiempo. En contraste, Mejía y Aguilar (2024) señalan que las series reales frecuentemente violan este supuesto, requiriendo transformaciones previas que pueden eliminar información valiosa.

La evolución del forecasting ha transitado desde métodos estadísticos clásicos hacia técnicas de machine learning más flexibles. Históricamente, métodos como ARIMA y

Exponential Smoothing dominaron el campo por su simplicidad e interpretabilidad (Mejía & Aguilar, 2024). No obstante, Praveena y Prasanna Devi (2024) documentan que algoritmos modernos como LSTM y CNN generan pronósticos más confiables al manejar patrones no lineales sin restricciones distribucionales estrictas. Esta transición refleja la búsqueda de herramientas que balanceen precisión con facilidad de uso empresarial.

### ***Arquitectura y Fundamentos Técnicos del Modelo Prophet***

Prophet fue desarrollado por Facebook como una herramienta de forecasting diseñada para usuarios empresariales sin conocimiento estadístico profundo. Taylor y Letham (2018) lo introdujeron como una solución de código abierto que combina sofisticación técnica con facilidad de uso, abordando las limitaciones de métodos tradicionales en contextos comerciales reales. El objetivo era crear un modelo suficientemente flexible para capturar patrones complejos pero transparente para facilitar la toma de decisiones empresariales (Taylor & Letham, 2018).

El núcleo de Prophet es un modelo aditivo descomponible expresado matemáticamente como:  $y(t) = g(t) + s(t) + h(t) + \varepsilon(t)$ , donde cada componente cumple una función específica (Fredén & Larsson, 2020). Asati (2022) explica que  $g(t)$  modela la tendencia no periódica,  $s(t)$  captura variaciones estacionales,  $h(t)$  incorpora efectos de eventos especiales como feriados, y  $\varepsilon(t)$  representa ruido que el modelo no puede explicar. Esta descomposición facilita tanto la interpretación como la incorporación de conocimiento empresarial específico (Praveena & Devi, 2024).

La componente de tendencia  $g(t)$  utiliza funciones lineales por tramos o logísticas saturadas, expresándose como  $g(t) = (k + a^T \delta)t + m + a^T \gamma$ , donde  $k$  representa la tasa de crecimiento base (Praveena & Devi, 2024). La estacionalidad  $s(t)$  emplea series de Fourier:

$s(t) = \sum_{n=1}^N (a_n \cos(2\pi n t/P) + b_n \sin(2\pi n t/P))$ , permitiendo modelar múltiples

estacionalidades simultáneas (diaria, semanal, anual) (Praveena & Devi, 2024). Finalmente, la componente  $h(t)$  maneja eventos irregulares como promociones o feriados, permitiendo especificar ventanas de influencia asimétricas que capturan efectos anticipatorios y residuales (Fredén & Larsson, 2020). Ensañi et al. (2022) validan esta capacidad empíricamente, demostrando que incorporar efectos de feriados reduce el MAPE de 28.89% a 22.62% en datasets de retail.

### ***Prophet en Perspectiva Comparativa: ARIMA y XGBoost***

Los modelos ARIMA representan décadas de investigación en análisis estadístico de series temporales. Asati (2022) los define como la combinación de componentes autoregresivos, integrados y de media móvil, donde los términos autorregresivos utilizan valores pasados para predicción lineal. Mejía y Aguilar (2024) establecen que ARIMA constituye uno de los métodos más utilizados para pronóstico temporal debido a su sólida fundamentación teórica. Pese a ello, estos modelos enfrentan limitaciones importantes: requieren estacionaridad previa mediante diferenciación, proceso que puede eliminar información valiosa sobre tendencias complejas (Fredén & Larsson, 2020).

XGBoost emerge como alternativa moderna de machine learning que supera restricciones tradicionales. Asati (2022) lo define como una implementación optimizada de gradient boosting que combina múltiples aprendices débiles mediante aproximación iterativa. Fredén y Larsson (2020) explican que utiliza ensambles de árboles de decisión donde cada iteración corrige errores anteriores, permitiendo manejar naturalmente no linealidades e interacciones complejas sin transformaciones previas extensivas.

Las ventajas del machine learning sobre métodos estadísticos tradicionales son evidentes en múltiples aspectos. Mejía y Aguilar (2024) documentan que técnicas de ML identifican

patrones no lineales con menos restricciones distribucionales, mientras que Praveena y Devi (2024) confirman que generan pronósticos más confiables en contextos complejos Wellens, Boute y Udenio (2024) añaden que métodos basados en árboles simplifican la complejidad computacional mientras aportan mayor interpretabilidad, equilibrando precisión con comprensibilidad empresarial. Esta evolución posiciona a Prophet como solución híbrida que preserva robustez estadística mientras simplifica implementación práctica.

### ***Aplicaciones de Prophet en Retail y Evaluación de Desempeño***

Las aplicaciones de Prophet en retail han demostrado resultados consistentemente superiores a métodos tradicionales. Žunić et al. (2021) documentan implementaciones exitosas donde Prophet, combinado con técnicas de backtesting, logra pronósticos confiables y permite clasificar productos según fiabilidad predictiva, facilitando estrategias diferenciadas de gestión de inventarios. Ensafi et al. (2022) reportan mejoras tangibles: Prophet alcanza MAPE de 22.62% y RMSE de 167.29 al incorporar efectos de feriados, superando significativamente el MAPE de 28.89% obtenido por SARIMA en contextos idénticos. Estas mejoras se traducen en reducciones concretas de errores de pronóstico y optimización de decisiones operacionales.

Estudios específicos validan la efectividad de Prophet en diferentes contextos comerciales. Fredén y Larsson (2020) demuestran su capacidad superior para manejar patrones estacionales complejos en supermercados suecos, incorporando conocimiento específico sobre promociones y eventos locales. Negre et al. (2024) extienden esta validación al sector calzado, donde Prophet obtiene una precisión del 98.8% frente al 93% de SARIMA en predicciones a largo plazo con alta estacionalidad.

La sistematización de métricas de desempeño confirma la superioridad predictiva de Prophet en contextos retail específicos. Hasan et al. (2022) evalúan comparativamente Prophet,

ARIMA y LightGBM sobre el dataset M5 de Walmart, evidenciando que Prophet mantiene robustez superior ante variabilidad en calidad de datos. Mehmood et al. (2024) reportan MAE de 22.7 para Prophet comparado con métricas superiores para ARIMAX, estableciendo jerarquías de rendimiento contextuales. La sistematización identifica factores críticos: disponibilidad mínima de 24 meses de historia según Žunić et al. (2021), incorporación de efectos calendarios para optimización, y preprocesamiento especializado documentado por Fredén y Larsson (2020), estableciendo lineamientos operacionales para implementación efectiva.

### ***Consideraciones de Implementación y Limitaciones***

La adopción exitosa de Prophet en entornos empresariales requiere consideraciones técnicas y organizacionales específicas. Atanda et al. (2024) establecen que el pronóstico de ventas proporciona valor a toda la organización, donde los departamentos de finanzas dependen de pronósticos para presupuestar planes de capacidad y contratación, los equipos de producción utilizan pronósticos de ventas para planificar sus ciclos, y la cadena de suministro aprovecha pronósticos para compras de materiales y capacidad de producción. Esta integración transversal requiere frameworks específicos de implementación que consideren necesidades departamentales diversificadas.

Las limitaciones identificadas incluyen dependencias críticas de calidad de datos históricos y desafíos de integración tecnológica. Fredén y Larsson (2020) documentan que la implementación efectiva de Prophet enfrenta obstáculos relacionados con disponibilidad y consistencia de datos, así como compatibilidad con sistemas tecnológicos existentes en organizaciones. Los desafíos específicos incluyen manejo de datos faltantes, incorporación de variables exógenas complejas, y calibración de hiperparámetros para diferentes categorías de productos.

La evaluación crítica de limitaciones revela áreas de mejora continua. Page et al. (2021) establecen que las revisiones sistemáticas proporcionan una síntesis del estado del conocimiento en un área determinada, identificando futuras prioridades de investigación y generando teorías sobre cómo ocurren fenómenos de interés. Por consiguiente, la adopción exitosa requiere no solo herramientas técnicas apropiadas, sino también cambios organizacionales y capacitación especializada para maximizar el valor empresarial de implementaciones predictivas.

### **Marco Conceptual**

La comprensión de Prophet como herramienta de inteligencia de negocios para retail requiere establecer un marco conceptual que integre fundamentos de series temporales, algoritmos predictivos, métricas de evaluación y consideraciones de implementación empresarial. Esta conceptualización permite vincular la teoría estadística con la práctica operativa, facilitando la adopción efectiva del modelo en contextos comerciales reales.

### ***Forecasting y Conceptos Fundamentales***

El forecasting se define como la utilización de una metodología computarizada para estimar valores futuros basados en la secuencia pasada observada de valores (Asati, 2022). El demand forecasting desempeña un papel central en un plan exitoso de cadena de suministro y los niveles de servicio ofrecidos a los clientes (Mejía & Aguilar, 2024), estableciendo el contexto estratégico donde Prophet opera como herramienta predictiva.

El sales forecasting constituye una aplicación específica del pronóstico temporal orientada hacia la predicción de ventas comerciales. Esta práctica resulta crítica en entornos donde los errores de pronóstico pueden ser perjudiciales para el sector, requiriendo máxima precisión posible (Mejía & Aguilar, 2024). Las empresas retail se caracterizan por la alta

variedad de productos que ofrecen, situación que las obliga a desarrollar procesos complejos que dependen de planes de suministro basados en pronósticos de demanda (Mejía & Aguilar, 2024).

Las series temporales constituyen el fundamento matemático del forecasting, definiéndose como datos recopilados a lo largo del tiempo donde el tiempo es un aspecto de los datos que contiene información importante. Fredén y Larsson (2020) establecen que el orden de los datos resulta importante ya que los puntos de datos sucesivos pueden estar correlacionados. Esta correlación temporal permite que valores anteriores en la serie temporal puedan ser un gran predictor de los siguientes, principio que sustenta tanto métodos tradicionales como modernos de pronóstico.

### ***Modelos y Algoritmos Predictivos***

La evolución de los algoritmos predictivos ha transitado desde enfoques estadísticos tradicionales hacia técnicas de machine learning más sofisticadas. Prophet constituye un puente entre ambos paradigmas, siendo un modelo especialmente diseñado para pronosticar datos de series temporales que utiliza un modelo aditivo generalizado capaz de agregar sin esfuerzo diferentes variables como feriados nacionales o eventos, tipos de eventos, tendencias diarias, semanales, bisemanales, mensuales, trimestrales y anuales (Hasan M. R., Kabir, Shuvro, & Das, 2022).

ARIMA representa el paradigma estadístico clásico, considerando tres componentes diferentes de datos históricos: términos autorregresivos, promedio móvil y términos de diferenciación. Hasan et al. (2022) explican que estos componentes se especifican frecuentemente con un modelo como ARIMA (p, d, q) que define que este modelo utiliza p términos autorregresivos, q términos de promedio móvil y d diferencias. XGBoost emerge como representante del paradigma de machine learning, siendo un concepto que se deriva del artículo

de Friedman sobre "Aproximación de Función Codiciosa: Una Máquina de Impulso de Gradiente" (Asati, 2022).

La distinción fundamental entre estos enfoques radica en sus supuestos subyacentes y flexibilidad operativa. Prophet generalmente hace un buen trabajo manejando valores atípicos y es resistente al patrón faltante de datos y cambios de tendencia, ejecutando pronósticos para conjuntos de datos de series temporales univariadas (Asati, 2022). Esta robustez operativa lo posiciona como herramienta intermedia que combina sofisticación técnica con facilidad de uso empresarial.

### ***Métricas de Evaluación***

La evaluación del desempeño predictivo requiere métricas cuantitativas que capturen diferentes dimensiones del error. MAPE (Mean Absolute Percentage Error) constituye una medida para determinar la precisión del método de pronóstico, típicamente expresada como porcentaje mediante la fórmula:  $MAPE = \left(\frac{100\%}{n}\right) \sum \left|\frac{A_t - F_t}{A_t}\right|$  donde  $A_t$  denota el valor actual y  $F_t$  denota el valor predicho (Asati, 2022). MAPE se sugiere para trabajos donde es más crítico ser sensible a diferencias relativas que a variaciones absolutas.

RMSE (Root Mean Square Error) representa la desviación estándar de los residuos, indicando el grado en que los datos se concentran alrededor de la línea de mejor ajuste mediante la fórmula:  $RMSE = \sqrt{\frac{\sum (F_t - A_t)^2}{n}}$ , donde  $f$  representa el valor pronosticado y  $o$  representa los valores reales (Asati, 2022). La complementariedad de estas métricas permite una evaluación integral del desempeño, ya que MAPE captura errores relativos mientras RMSE penaliza más severamente errores grandes.

La selección apropiada de métricas debe considerar el contexto operativo específico. En retail, donde diferentes productos presentan escalas de ventas heterogéneas, métricas como

MAPE que normalizan por el nivel de ventas facilitan comparaciones entre SKUs, mientras que RMSE proporciona sensibilidad a errores absolutos críticos para gestión de inventarios de alto volumen.

### ***Inteligencia de Negocios y Aplicaciones***

La inteligencia de negocios proporciona el contexto operativo donde Prophet se implementa como herramienta de soporte decisional. Massaro et al. (2021) definen Business Intelligence como el conjunto de procesos y tecnologías utilizadas para recopilar, analizar y hacer que los datos sean utilizables con el fin de tomar mejores decisiones. Los mismos autores establecen que BI utiliza análisis frontal mediante dashboards, Sistemas de Información Ejecutiva (EIS) y herramientas de TI destinadas a apoyar actividades gerenciales, específicamente Sistemas de Soporte a la Decisión (DSS). En este marco, Prophet funciona como componente analítico que transforma datos históricos de ventas en insights predictivos accionables, donde el objetivo final es proporcionar soporte para la toma de decisiones (Massaro, Panarese, Giannone, & Galiano, 2021).

El forecasting en retail enfrenta desafíos específicos que Prophet está diseñado para abordar, incluyendo alta estacionalidad, efectos de eventos promocionales, tendencias cambiantes y necesidad de interpretabilidad para equipos no técnicos. AbdElminaam et al. (2024) destacan que la interpretabilidad y facilidad de uso de Prophet constituyen dos de sus principales beneficios, facilitando la comunicación de resultados a stakeholders empresariales. La capacidad del modelo para descomponer series temporales en componentes interpretables (tendencia, estacionalidad, efectos de feriados) permite incorporar conocimiento del dominio en las especificaciones técnicas.

La integración con sistemas de BI requiere consideraciones de escalabilidad, automatización y visualización. Mohamad et al. (2023) describen que las aplicaciones de BI funcionan como plataformas de visualización para manejar datos de productos, proveedores, transacciones de ventas y compras, y datos de clientes en dashboards, conteniendo componentes de fuente de datos, ETL (Extract, Transform, and Load), almacén de datos, dashboards interactivos y reportes. Los mismos autores establecen que herramientas como Power BI mejoran la gestión de datos, y sus reportes y visualizaciones ayudan a ejecutivos en la toma de decisiones. Prophet debe operar dentro de estos pipelines de datos que actualicen pronósticos periódicamente, generen alertas ante desviaciones significativas y produzcan reportes ejecutivos que traduzcan precisión estadística en recomendaciones operativas concretas.

### ***Conceptos Técnicos Especializados***

Los conceptos técnicos especializados proporcionan la base metodológica para implementación efectiva de Prophet. Estacionaridad constituye un concepto fundamental que requiere que la varianza, media y estructura de autocorrelación no deberían variar con el tiempo en un conjunto de datos estacionario (Asati, 2022). La ventaja de Prophet radica en que no requiere transformaciones previas para lograr estacionaridad, manejando naturalmente tendencias y cambios estructurales.

Cross-validation y backtesting constituyen técnicas fundamentales de evaluación. Atanda et al. (2024) explican que la validación cruzada se utiliza comúnmente para dividir conjuntos de datos con el fin de obtener una evaluación más robusta, donde la técnica de k-fold divide los datos en k subconjuntos (folds), donde cada fold sirve como conjunto de validación mientras el resto se utiliza para entrenamiento. Žunić et al. (2021) complementan estableciendo que para verificar la calidad del modelo se utiliza backtesting, donde cualquier momento en el historial de

datos se establece como el tiempo actual, todos los datos anteriores se utilizan como historial para crear el modelo, mientras que los datos más nuevos se utilizan para pruebas, permitiendo realizar pruebas sin esperar eventos futuros.

Big Data se caracteriza por observaciones indexadas por marcas de tiempo, dando lugar a series temporales de big data caracterizadas por alta frecuencia y largo período de tiempo (Petropoulos, y otros, 2022). Los mismos autores advierten que los beneficios de big data no son tan evidentes en un contexto de forecasting donde los valores futuros de todas las variables agregadas también necesitan ser pronosticados y son tan inciertos como las variables de interés. La arquitectura de Prophet está diseñada para manejar eficientemente estos volúmenes de datos, facilitando forecasting a escala empresarial sin requerir infraestructura computacional especializada.

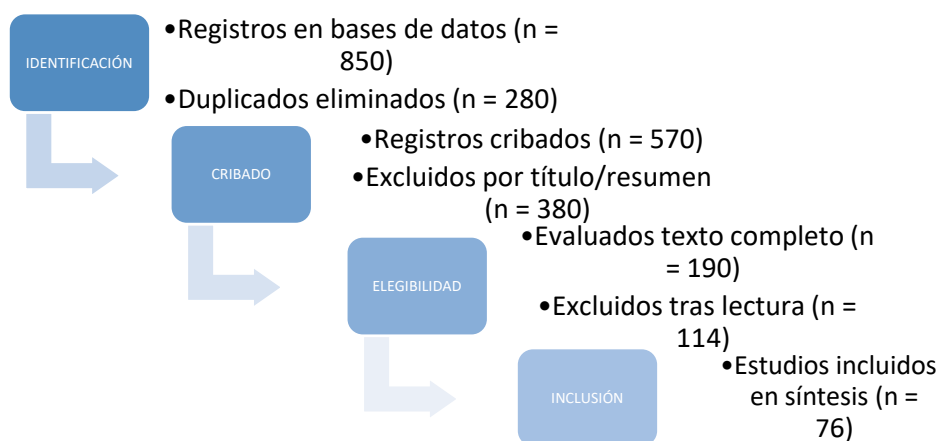
## Metodología

Esta investigación adoptó un diseño documental de naturaleza exploratoria y cualitativa. El análisis se centró en la literatura científica sobre modelos predictivos de ventas en retail, con énfasis particular en Prophet y su comparación con técnicas estadísticas tradicionales (ARIMA) y de machine learning (XGBoost). El proceso metodológico siguió el protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), reconocido por Page et al. (2021) como el estándar internacional para revisiones sistemáticas rigurosas en ciencias aplicadas.

La búsqueda documental abarcó cinco bases de datos internacionales: Scopus, ScienceDirect, IEEE Xplore, Google Scholar y SpringerLink. El horizonte temporal se delimitó entre 2017 y 2025, considerando que Taylor y Letham (2018) introdujeron Prophet en 2017. Esta ventana permitió capturar tanto la adopción inicial del modelo como las innovaciones recientes reportadas por la literatura. Se incluyeron publicaciones en español e inglés para maximizar la cobertura geográfica y contextual del análisis, cuyo esquema general se presenta en la Figura 1.

### Figura 1

*Diagrama de Flujo del Proceso de Selección Según Protocolo PRISMA*



## **Criterios de Selección y Exclusión**

La selección de fuentes obedeció a criterios explícitos definidos a priori. Se incluyeron investigaciones empíricas, simulaciones, estudios de caso y metaanálisis que cumplieran tres condiciones: (1) aplicación directa de Prophet a predicción de ventas, demanda o inventarios en retail; (2) comparación explícita de Prophet con al menos un modelo alternativo; y (3) reporte de métricas de desempeño cuantificables. Atanda et al. (2024) validan esta aproximación al enfatizar que la preparación de datos y la validación cruzada son fases esenciales para garantizar modelos apropiados en machine learning.

Los criterios de exclusión eliminaron trabajos no científicos, aplicaciones tangenciales al retail (como salud o finanzas) y textos en idiomas distintos al español o inglés. Žunić et al. (2021) justifican esta rigurosidad al señalar que los datos reales de retail presentan desafíos únicos como alta no estacionaridad, ventas irregulares y efectos de feriados que requieren análisis especializado.

El proceso de cribado se ejecutó manualmente en cuatro fases secuenciales. Primero, se aplicaron ecuaciones de búsqueda combinando términos como "Prophet", "sales forecasting", "retail", "demand prediction" y "time series". Ensafi et al. (2022) utilizan estrategias similares al segmentar datasets por granularidad temporal (diaria, mensual) para optimizar la detección de artículos pertinentes. Segunda fase: preselección mediante revisión de títulos y resúmenes. Tercera: lectura completa de textos candidatos. Cuarta: evaluación contra criterios de inclusión establecidos.

## **Análisis y Síntesis de la Información**

Los artículos seleccionados se sometieron a análisis temático estructurado. Los hallazgos se codificaron en categorías operacionales: (1) precisión predictiva y métricas de error (MAPE,

MAE, RMSE); (2) sector de aplicación y características del dataset; (3) tratamiento de estacionalidades múltiples; (4) incorporación de variables exógenas como promociones y feriados; y (5) impacto en automatización y visualización para BI.

La síntesis empleó dos enfoques complementarios. El narrativo permitió identificar patrones comunes entre Prophet, ARIMA y XGBoost, destacando fortalezas relativas según contexto operativo. El cuantitativo facilitó comparaciones directas de desempeño mediante agregación de métricas reportadas. Hasan et al. (2022) validan esta dualidad al comparar Prophet, ARIMA y LightGBM sobre el dataset M5 de Walmart, demostrando que el rendimiento óptimo depende intrínsecamente de las características específicas de cada conjunto de datos.

Este diseño permitió establecer conexiones claras entre variables técnicas (como capacidad de modelar estacionalidades) y resultados operativos (como reducción de errores en gestión de inventarios). La metodología implementada garantizó que las conclusiones estuvieran respaldadas por evidencia empírica reciente y contextualizada al sector retail.

## **Revisar y Sistematizar la Literatura Científica Reciente Sobre el Uso del Modelo Prophet en la Predicción de Ventas en el Sector Retail**

La sistematización de la literatura científica sobre aplicaciones de Prophet en retail se fundamentó en la revisión exhaustiva de estudios empíricos que documentan implementaciones específicas del modelo. La selección privilegió investigaciones que reportaran aplicaciones directas con métricas cuantificables y contextos operacionales documentados, permitiendo caracterizar patrones sistemáticos en la adopción práctica del modelo.

### **Caracterización Sistemática de Datasets Documentados**

Las implementaciones de Prophet en retail abarcan escalas operativas diversificadas, desde aplicaciones individuales hasta portafolios masivos. Praveena y Prasanna Devi (2024) documentan la aplicación al dataset M5 de Walmart, que comprende 3,049 productos clasificados en tres categorías principales distribuidos en 10 tiendas ubicadas en California, Texas y Wisconsin, con datos diarios que abarcan 1,969 días correspondientes a 5.4 años de operación histórica. Contrastando con esta escala masiva, Ji et al. (2019) implementan Prophet en series temporales de 381 días para e-commerce transfronterizo chino, mientras que Fredén y Larsson (2020) evalúan su desempeño en cuatro supermercados suecos con datos de dos años. Las divisiones metodológicas train/test varían sistemáticamente: Praveena y Prasanna Devi (2024) emplean división 70/30, Asati (2022) utiliza 90/10 con períodos de entrenamiento desde enero 2011 hasta octubre 2020, y Hasan et al. (2022) implementan validación temporal específica para predicción de 28 días subsecuentes. Esta variabilidad metodológica refleja la adaptabilidad de Prophet a diferentes contextos operacionales y requerimientos predictivos.

## **Taxonomía de Sectores y Productos Analizados**

La literatura documenta aplicaciones sectoriales específicas que revelan la versatilidad de Prophet en contextos retail heterogéneos. Negre et al. (2024) validan su efectividad en el sector calzado, caracterizado por alta estacionalidad y tendencias de moda, donde Prophet alcanza precisión del 98.8% superando significativamente el 93% de SARIMA. Mejía y Aguilar (2024) sistematizan aplicaciones en las categorías Hobbies, Foods y Household del retail estadounidense, identificando que productos con alta autocorrelación y demanda media constante favorecen el rendimiento de Prophet. Fredén y Larsson (2020) extienden la validación a supermercados europeos incorporando variables climáticas y eventos promocionales locales, mientras que Mehmood et al. (2024) documentan aplicaciones en máquinas expendedoras del Reino Unido. Geográficamente, las implementaciones abarcan contextos desarrollados y emergentes: Asati (2022) evalúa Prophet para índices macroeconómicos en India, Žunić et al. (2020) implementan backtesting en retail de Bosnia-Herzegovina, y Chang et al. (2025) incorporan festivales específicos y políticas gubernamentales en contextos asiáticos, demostrando la capacidad del modelo para adaptarse a patrones culturales y regulatorios diferenciados.

## **Sistematización de Horizontes Predictivos Documentados**

Los horizontes temporales implementados revelan patrones sistemáticos correlacionados con propósitos operacionales específicos. El horizonte de 7-28 días predomina en aplicaciones operativas: Hasan et al. (2022) implementan predicción de 28 días para optimización de inventarios Walmart, Praveena y Prasanna Devi (2024) evalúan horizontes semanales para gestión de productos estacionales, y Fredén y Larsson (2020) documentan forecasting diario para reposición automática en supermercados. Los horizontes de mediano plazo (1-12 meses) se

concentran en planificación estratégica: Negre et al. (2024) implementan predicción anual para planificación de colecciones en calzado, incorporando estacionalidades complejas y efectos de tendencias de moda. La granularidad temporal varía según características del sector: datos diarios dominan en retail de alta rotación documentado por Praveena y Prasanna Devi (2024), granularidad semanal se implementa para productos de rotación media según Mejía y Aguilar (2024), y periodicidad mensual se aplica para planificación estratégica como documenta Asati (2022). Factores determinantes incluyen volatilidad intrínseca del producto, ciclos estacionales superpuestos, y requerimientos organizacionales de planificación, donde Prophet demuestra robustez superior ante irregularidades y datos faltantes comparado con modelos tradicionales.

### **Métricas de Evaluación por Contexto de Aplicación**

Las métricas de evaluación evidencian rangos de rendimiento correlacionados con complejidad contextual y calidad de datos. Asati (2022) reporta MAPE excepcional de 0.44% para Prophet en predicción de índices macroeconómicos indios, contrastando con MAPE de 1.18% para LSTM y 2.09% para XGBoost en contextos idénticos. Praveena y Prasanna Devi (2024) documentan MAPE de 15% con RMSE de 98 para productos estacionales, mejorando hasta 99.2% de precisión al incorporar efectos de feriados. AbdElminaam et al. (2024) reportan MAE de 0.015 para datasets Walmart versus 0.03 para XGBoost y redes neuronales. Mehmood et al. (2024) confirman superioridad de Prophet con MAE de 22.7 comparado con ARIMAX, estableciendo jerarquías de rendimiento contextuales. La sistematización identifica factores críticos: disponibilidad mínima de 24 meses de historia según Žunić et al. (2020), incorporación de efectos calendarios para optimización según Chang et al. (2025), y preprocesamiento especializado documentado por Fredén y Larsson (2020), estableciendo lineamientos operacionales para implementación efectiva.

## **Comparar las Capacidades de Prophet Frente al Modelo Clásico ARIMA y Moderno XGBoost, Analizando Precisión, Interpretabilidad y Facilidad de Integración en Entornos de BI**

### **Introducción y Contextualización**

Este análisis se enfoca en determinar la aplicabilidad y el valor estratégico del modelo Prophet en la Inteligencia de Negocios (BI) para el sector retail, lo cual exige un contraste riguroso de sus capacidades predictivas. Dicha comparación se centra en evaluar el desempeño de Prophet frente a otras dos técnicas de predicción fundamentales: el modelo estadístico clásico ARIMA y el moderno algoritmo de machine learning XGBoost. La elección de este trío responde a la necesidad de confrontar la simplicidad y transparencia intrínseca de Prophet con la tradición de la estadística de series temporales (ARIMA) y la probada potencia predictiva de los modelos de ensamble (machine learning, XGBoost) (Mejía & Aguilar, 2024).

La justificación de este análisis es la búsqueda de una solución de forecasting que impacte directamente en la gestión de inventarios, la planificación comercial y consecuentemente, en la toma de decisiones estratégicas (Mohamad, y otros, 2023; Baron, 2024). Las investigaciones enfatizan que, para el forecasting individualizado de productos, es una práctica recurrente el entrenamiento y evaluación de varios modelos, incluyendo ARIMA, SARIMAX, Prophet, XGBoost y ensamblados híbridos, para seleccionar el algoritmo más eficiente en cada categoría y segmento estudiado (Mejía & Aguilar, 2024).

La estructura de este análisis se cimienta en una conceptualización breve y operativa de cada arquitectura, donde las diferencias fundamentales emergen de sus diseños algorítmicos y filosofías predictivas. ARIMA constituye un modelo lineal que se basa en la autocorrelación de la serie temporal, requiriendo que los datos sean estacionarios y demandando una identificación

manual de los órdenes (p, d, q), lo que dificulta su escalabilidad en el retail multirubro (Baron, 2024, pág. 4). En contraste, Prophet representa un modelo aditivo de regresión que se basa en la descomposición de la serie en componentes de tendencia, estacionalidad y feriados, confiriendo una alta interpretabilidad nativa a través de la visualización directa de sus gráficos de componentes y destacando por la facilidad para incluir efectos de calendario como regresores exógenos (Mejía & Aguilar, 2024). Por su parte, XGBoost se configura como un algoritmo de gradient boosting basado en árboles de decisión que sobresale por su capacidad de capturar relaciones no lineales y explotar una gran cantidad de variables exógenas, siendo altamente efectivo en la predicción pero enfrentando el desafío de la baja interpretabilidad nativa (Ji, Wang, & Zhao, 2019).

Este análisis, por lo tanto, se estructura bajo la evaluación de tres criterios clave: la precisión predictiva, la interpretabilidad de sus resultados y la facilidad de integración en entornos operacionales.

### **Resultados Comparativos de Precisión: Contexto Metodológico y Hallazgos**

El análisis de la precisión predictiva es el pilar central de la comparación tripartita (Prophet, ARIMA y XGBoost), ya que el rendimiento del modelo es esencial para la optimización del inventario y las ventas (Anusha & Maiti, 2025). Su validez depende del riguroso marco metodológico bajo el cual los modelos son evaluados en la literatura científica. Por lo tanto, esta sección fusiona el contexto experimental con la presentación de los principales hallazgos de rendimiento.

#### ***Contexto de Evaluación y Metodología Experimental***

La rigurosidad de la comparación se establece a partir de las condiciones experimentales que replican las exigencias operativas del retail. Los estudios se sustentan en conjuntos de datos que

replican estas condiciones, abarcando desde información de supermercados en tiempo real (Žunić E. , Korjenić, Hodžić, & Đonko, 2020) hasta benchmarks de alta dimensión como el desafío M5 de Walmart (Hasan M. R., Kabir, Shuvro, & Das, 2022)

**Granularidad y la Ingeniería de Características.** La granularidad es típicamente a nivel de producto o categoría, lo que implica lidiar con series de tiempo complejas y el impacto de múltiples variables externas. Un consenso metodológico fundamental es que la Ingeniería de Características es una precondition para maximizar el rendimiento de los modelos modernos. Los autores Mejía y Aguilar (2024) establecen que la aplicación de una robusta ingeniería de características, que incluye variables exógenas como rezagos temporales y efectos de calendario, es esencial para maximizar el rendimiento de cada modelo. El éxito de modelos como XGBoost depende de manera crítica de esta inversión en la manipulación de variables de entrada.

**Validación Temporal y Métricas de Error.** Para asegurar que los resultados sean representativos del despliegue en BI, la validación se realiza mediante esquemas que simulan la realidad operacional, donde el futuro siempre es incierto. Por ello, la validación mantiene el orden temporal estricto de los datos, una práctica necesaria para series de tiempo (Atanda, y otros, 2024).

La literatura prioriza métricas que ofrecen diferentes perspectivas sobre el costo del error:

**Tabla 1**

*Métricas de Error de Predicción y su Relevancia Operacional en Retail*

Métrica de Error	Aplicación en Retail
RMSE (Error Cuadrático Medio de la Raíz)	Penaliza fuertemente los errores grandes, siendo crítica para la gestión de stock donde el sobre o sub-pronóstico tiene alto costo.

Métrica de Error	Aplicación en Retail
MAE (Error Absoluto Medio)	Ofrece una medida del error promedio en las mismas unidades que la venta, siendo más intuitiva para la gestión diaria.
MAPE/sMAPE (Error Porcentual Absoluto Medio)	Facilita la comparabilidad entre diferentes categorías o escalas de ventas, pues se expresa como un porcentaje.

### ***Jerarquía de Rendimiento y Hallazgos de Precisión***

Los resultados académicos establecen una jerarquía de rendimiento donde los modelos de Machine Learning superan a la aproximación estadística, aunque con importantes dependencias del conjunto de datos.

**XGBoost: Potencia en No Linealidad y Máximo Rendimiento.** GBoost demuestra consistentemente el mayor potencial de precisión al pronosticar series de tiempo de ventas minoristas (Malik, Khan, Abid, & Aslam, 2024). Su arquitectura de boosting le permite capturar interacciones no lineales y relaciones complejas entre variables, superando el límite de la linealidad de modelos clásicos. Estudios comparativos directos concluyen que el modelo es líder en el desempeño de métricas sensibles al costo del error, reportando que: "The XGBoost model outperforms the others in terms of RMSE (727.13), MSE (528718.04), and MAE (261.29)" (Atanda, y otros, 2024, pág. 7). Esta superioridad se atribuye a su capacidad para capturar mejor los patrones subyacentes y las variaciones estacionales en los datos de ventas (Atanda, y otros, 2024), un factor esencial para la predicción precisa de ventas en tienda (AbdElminaam, y otros, 2024)

**Prophet: Robustez Competitiva y Dominio de la Estacionalidad.** El modelo Prophet se establece como la solución aditiva de mejor balance entre rendimiento y facilidad operacional. La literatura valida su competitividad al demostrar que es un un mejor modelo de predicción que el modelo clásico ARIMA para el pronóstico de ventas minoristas (Jha, 2021). Su diseño aditivo, con flexibilidad para modelar estacionalidad múltiple y eventos explícitos como regresores, lo convierte en un factor crítico para el sector retail, por lo que su enfoque lo hace ideal para la predicción de ventas de artículos estacionales (Žunić et al. 2020; Ensafi et al.. 2022).

**ARIMA: Limitación Estructural por Linealidad.** El modelo ARIMA tiende a ser superado por los modelos modernos en series de retail con alta estacionalidad y necesidad de incorporar eventos externos (Atanda, y otros, 2024). Sus limitaciones son estructurales, pues su dependencia de supuestos de linealidad lo hace ineficiente para capturar las complejas interacciones de variables presentes en el comportamiento de compra (Jha, 2021).

### ***El Contrapunto Académico y la Dependencia del Conjunto de Datos***

El rigor académico exige evitar la conclusión de una superioridad absoluta. El estudio de Hasan, M. R., et al. (2022), que utilizó el benchmark del desafío M5 de Walmart, reportó un hallazgo fundamental donde el "ARIMA model outperforms the Facebook Prophet and LightGBM model" (el modelo ARIMA supera a Facebook Prophet y al modelo LightGBM) (Hasan M. R., Kabir, Shuvro, & Das, 2022). Este contrapunto subraya que el rendimiento óptimo es intrínsecamente dependiente de la naturaleza, complejidad y características del conjunto de datos particular. Este fenómeno justifica la necesidad de realizar un "benchmark" robusto que incluya la comparación de los tres modelos (Malik, Khan, Abid, & Aslam, 2024) y, en última instancia, considera la adopción de modelos híbridos (Iñiguez, 2025) para lograr la "gestión predictiva de inventario" más eficiente (S, M, H, & A., 2024).

## Interpretabilidad y Explicabilidad

La interpretabilidad y la explicabilidad en el contexto de la Inteligencia de Negocios (BI) para la previsión de la demanda se han consolidado no como meras funciones secundarias, sino como un requisito operativo esencial. Un pronóstico se vuelve verdaderamente accionable solo en la medida en que el actor comercial es capaz de comprender las justificaciones detrás de la predicción, lo cual es la base de la confianza y la capacidad de reacción ante los datos. Este imperativo funcional expone la tensión crucial entre los modelos que ofrecen transparencia por diseño y aquellos que, a pesar de su superioridad en precisión, requieren de una explicabilidad post-hoc compleja.

El algoritmo Prophet ejemplifica la transparencia por diseño, una característica medular de su propuesta original según Taylor y Letham (2018) quienes lo definieron como un modelo aditivo capaz de descomponer la serie de tiempo de forma nativa. Esta descomposición, que aísla la tendencia, las estacionalidades (diaria, semanal, anual) y el impacto de días festivos o eventos, hace que la predicción total sea la suma de componentes fácilmente aislables y visualizables. Tal como enfatizaron Žunić et al. (2020) al evaluar su aplicación en el sector minorista, la explicabilidad de Prophet es inherentemente intuitiva debido a estos gráficos de componentes. Esta modularidad facilita de manera significativa el diagnóstico operacional al permitir al analista, incluso con experiencia limitada en estadística avanzada, inspeccionar y manipular los componentes directamente, mejorando el entendimiento del impacto específico de un feriado o una campaña promocional (Baron, 2024, pág. 4).

En marcado contraste, modelos basados en Machine Learning avanzado como XGBoost o los modelos híbridos de Deep Learning (DL) presentan un desafío sustancial a la transparencia. XGBoost, como algoritmo de boosting basado en árboles de decisión, es conceptualmente una

"caja negra", cuya complejidad en la interacción de miles de árboles hace que sea difícil determinar la contribución exacta de cada variable en una predicción individual (Atanda, y otros, 2024). La superioridad predictiva de estos enfoques es innegable; por ejemplo, Iñiguez-García (2025) explora un modelo híbrido Prophet/XGBoost para la predicción de demanda en retail automotivo, lo que subraya la necesidad de recurrir a la potencia de XGBoost para mejorar la precisión. Sin embargo, para que estos modelos complejos alcancen la transparencia requerida, su interpretabilidad se vuelve dependiente de la implementación de técnicas de Explicabilidad de Inteligencia Artificial (XAI). Esto implica el uso de recursos post-hoc como los Valores SHAP (SHapley Additive exPlanations) para desglosar la contribución de las variables, un paso que eleva significativamente el requerimiento técnico y la infraestructura necesaria. De forma similar, la investigación de Mehmood et al. (2024) que compara algoritmos de DL como CNN-LSTM para la previsión minorista, si bien demuestra la superioridad de estos modelos híbridos en precisión, indirectamente confirma que su adopción requiere un compromiso con herramientas XAI complejas para traducir las predicciones en información actionable. Finalmente, el modelo ARIMA ocupa una posición intermedia, ofreciendo una transparencia paramétrica clásica derivada de sus órdenes ( $p$ ,  $d$ ,  $q$ ) que reflejan las propiedades intrínsecas de autocorrelación y media móvil de la serie (Hasan M. R., Kabir, Shuvro, & Das, 2022). No obstante, esta transparencia es inherentemente limitada en el dinámico entorno minorista. Como señalan Atanda et al. (2024) los parámetros de ARIMA, aunque estadísticamente válidos para el diagnóstico, no se correlacionan fácilmente con los conceptos causales de negocio que son cruciales para un stakeholder, como el impacto de una promoción o un cambio en la competencia. Es decir, el modelo provee una estructura estadística sin una perspectiva directa sobre los impulsores externos de la demanda. Por consiguiente, aunque

estadísticamente transparente, su valor operativo para el analista de BI es bajo en comparación con la explicabilidad visual e inmediata de Prophet. En síntesis, aunque la alta precisión de modelos como XGBoost o los híbridos CNN-LSTM (S, M, H, & A., 2024) es un argumento de peso, la necesidad de interpretabilidad en BI otorga una ventaja decisiva al diseño modular de Prophet. Prophet sacrifica complejidad analítica por una explicabilidad nativa que permite un diagnóstico y una justificación rápida de las predicciones, mientras que los modelos de "caja negra" imponen la carga de implementar y mantener una costosa infraestructura de XAI para lograr un nivel de transparencia comparable.

**Tabla 2**

*Comparativa de Interpretabilidad y Recursos de Explicación*

Recurso de Explicación	Prophet	ARIMA	XGBoost
Enfoque Principal	Descomposición modular aditiva	Análisis de parámetros y residuos	Técnicas XAI (Post-Hoc)
Recursos Nativos para BI	Componentes de Tendencia, Estacionalidad y Efectos de Eventos	Parámetros (p,d,q) y Coeficientes.	Ranking de Variables (Importancia Global)
Requerimiento Técnico para Explicar	Bajo (Visualización nativa, fácil exportación)	Medio (Validación de residuos y órdenes)	Alto (Implementación de librerías SHAP y herramientas XAI)
Ventaja Operacional	Explicación inmediata y visual de los impulsores del pronóstico (diagnóstico rápido y justificado).	Transparencia estadística básica, útil solo para audiencias técnicas.	Explicación detallada de la contribución de cada variable a una predicción individual si se utiliza SHAP

## Facilidad de Integración y Despliegue en BI

La utilidad final de un modelo de forecasting en el sector retail trasciende su precisión algorítmica y se define, en última instancia, por su capacidad de ser integrado y escalado en los sistemas de Inteligencia de Negocios (BI). Este criterio, que evalúa el despliegue, el mantenimiento (MLOps) y la entrega de resultados a dashboards, es la prueba de fuego de la escalabilidad del modelo a través de miles de SKUs.

La facilidad de implementación y mantenimiento favorece notablemente a Prophet. Su diseño modular y su estructura aditiva simple, detallada por Taylor y Letham (2018) como fundamental para el "forecasting at scale", simplifican tanto su despliegue como su monitoreo. Esto reduce la deuda técnica y la complejidad de los pipelines de MLOps (Jha, 2021). Una de sus principales fortalezas operacionales es la facilidad de re-entrenamiento automático, un requisito fundamental para gestionar la naturaleza volátil de las series de tiempo en retail (Žunić E. , Korjenić, Hodžić, & Đonko, 2020), que buscan un sistema robusto de predicción de ventas basado en datos reales.

En marcado contraste, XGBoost demanda una mayor inversión en infraestructura de MLOps y un expertise técnico más elevado para su manejo. Atanda et al. (2024, pág. 4) coinciden en que el despliegue de XGBoost debe ser sistematizado bajo un proceso end-to-end que gestione infraestructura, pipelines y monitoreo constante, lo cual incrementa el riesgo y el esfuerzo de implementación. Este alto requerimiento técnico se debe a la necesidad de gestionar la ingeniería de variables y, crucialmente, de implementar técnicas post-hoc de explicabilidad (XAI) para que sus resultados puedan ser procesados y entendidos por los sistemas de BI. Por último, ARIMA, aunque es conceptualmente simple, es ineficiente en su integración a escala. El mismo estudio de Atanda et al. (2024) señala que la necesidad de realizar el análisis de residuos

y la identificación manual de los órdenes de manera periódica para miles de series lo hace inviable para la automatización masiva que requiere un entorno de BI moderno.

En cuanto a la Visualización para el Negocio, la modularidad de Prophet confiere una ventaja crítica. Al basarse en una descomposición modular aditiva, facilita la exportación directa de componentes (Tendencia, Estacionalidad, Efectos de Eventos) a paneles de control. Mientras que XGBoost, aunque ofrece una salida de pronóstico precisa, presenta una lectura indirecta de la importancia de variables, Prophet permite la explicación inmediata y visual de los impulsores del pronóstico, un recurso nativo para BI. Por su parte, ARIMA solo ofrece el valor de la predicción final, sin los componentes desagregados, lo que limita significativamente su utilidad para el diagnóstico en los paneles de control (Hasan M. R., Kabir, Shuvro, & Das, 2022).

La conclusión estratégica es que la facilidad de ajuste y la claridad en el diagnóstico de Prophet superan los requerimientos técnicos avanzados de XGBoost en escenarios donde la prioridad es la rápida adopción y el uso generalizado por parte del equipo de BI. La baja barrera de entrada técnica de Prophet lo convierte en la herramienta más eficiente para lograr una cobertura masiva en el forecasting de retail.

## **Identificar los Factores Críticos de Éxito y Limitaciones en la Implementación de Prophet en Retail, Incluyendo Calidad de Datos, Estacionalidades Múltiples, Promociones y Quiebres de Inventario**

La predicción de ventas en el sector retail representa uno de los desafíos más complejos en el ámbito de la inteligencia de negocios, donde la precisión numérica debe traducirse en decisiones estratégicas que impacten la gestión de inventarios y la rentabilidad. Taylor y Letham (2018) concibieron Prophet como un procedimiento de pronóstico basado en un modelo aditivo donde las tendencias no lineales se ajustan junto con la estacionalidad anual, semanal y diaria, además de los efectos de días festivos, permitiendo que analistas sin formación estadística avanzada configuren modelos de manera intuitiva. Sin embargo, Žunić et al. (Žunić E. , Korjenić, Hodžić, & Đonko, 2020) demostraron al implementarlo en una compañía de retail de Bosnia y Herzegovina que su efectividad depende críticamente de la disponibilidad de datos históricos consistentes, la correcta configuración de eventos estacionales y la capacidad organizacional para interpretar las predicciones generadas.

Este capítulo examina esta realidad operativa mediante factores críticos de éxito versus limitaciones. Los primeros incluyen disponibilidad de datos de calidad, patrones estacionales definidos, incorporación de eventos como variables exógenas, detección de cambios de tendencia e interpretabilidad nativa. Las limitaciones abarcan productos de demanda intermitente, dificultades con series volátiles, impacto de quiebres de inventario y barreras de integración técnica. Atanda et al. (2024) refuerzan que la preparación de datos es esencial, incluyendo decisiones sobre granularidad temporal, identificación de eventos relevantes y estructuración de variables exógenas. Esta aproximación equilibrada busca establecer con precisión cuándo

Prophet representa la solución óptima y bajo qué circunstancias genera valor organizacional tangible en el contexto del retail.

## **Factores Críticos de Éxito**

### ***Calidad y Disponibilidad de Datos Históricos***

La efectividad de Prophet en retail está condicionada por la disponibilidad de datos históricos suficientes y de calidad adecuada. Este factor no es secundario: la descomposición de series temporales en tendencia, estacionalidad y efectos de eventos requiere observar suficientes ciclos para estimar estos componentes con robustez estadística.

**Umbral Mínimo de Historia.** La investigación ha establecido requisitos claros sobre cantidad de datos necesarios. Žunić et al. (2020) determinaron empíricamente que se necesitan al menos 24 meses de historia para estimación confiable de tendencia y efectos estacionales. Con menos de dos años, el modelo no captura ciclos anuales completos ni distingue entre variaciones estacionales legítimas y fluctuaciones aleatorias. Cuando se implementa backtesting, proceso esencial para evaluar la confiabilidad, el requerimiento se extiende a 39 meses: 24 para entrenamiento, 12 para validación cruzada y 3 adicionales para medir la precisión trimestral.

Esta dependencia de historiales extensos tiene consecuencias prácticas. Gärtner et al. (2024) confirmaron que productos con historial corto generan errores más elevados, lo cual es particularmente problemático en retail donde constantemente se lanzan nuevos productos o se expanden operaciones a mercados sin datos previos. Aquí el modelo enfrenta restricciones estructurales para pronósticos confiables.

**Robustez ante Imperfecciones de Datos.** Una ventaja distintiva de Prophet frente a modelos estadísticos clásicos es su tolerancia a imperfecciones. Mientras ARIMA exige series completas y estacionarias, Prophet maneja ausencias y outliers con menor preprocesamiento.

Barón y Carrascal (2024) destacan que "Prophet trabaja con datos faltantes con varios valores atípicos", reduciendo la inversión en limpieza exhaustiva de datos. Taylor y Letham (2018) explican que "a diferencia de los modelos ARIMA, las mediciones no necesitan estar espaciadas regularmente, y no necesitamos interpolar valores faltantes" (p. 39). Esta flexibilidad es valiosa en retail, donde sistemas de punto de venta experimentan caídas temporales o ciertos productos no registran ventas por razones operativas (cierres, mantenimiento).

Phalachandra et al. (2023) añaden que Prophet "puede manejar valores en blanco presentes en los datos y no necesita que los datos estén ordenados por fecha y hora", eliminando tareas de ordenamiento cronológico que en bases masivas representan costos computacionales significativos. Esta capacidad deriva de su formulación bayesiana, donde datos ausentes se tratan como parámetros latentes a estimar.

Sin embargo, esta robustez tiene límites. Zhao y Zhang (2020) advierten que aunque el modelo puede "completar automáticamente el valor faltante, sin mucho preprocesamiento", esto no significa que cualquier calidad sea aceptable. Anomalías masivas o patrones erráticos sesgan estimaciones de tendencia y estacionalidad, requiriendo intervención.

**Estrategias de Tratamiento de Outliers.** Cuando existen anomalías significativas, enfoques especializados resultan necesarios. Perera et al. (2024) documentan el uso del método STL (Seasonal and Trend decomposition using Loess) para corrección previa, destacando su "flexibilidad en el manejo de diferentes tipos de estacionalidad, modificaciones controladas por el usuario del componente estacional y resiliencia a valores atípicos" (p. 3). Esta estrategia híbrida reconoce que, aunque Prophet tolera imperfecciones, la calidad predictiva mejora sustancialmente eliminando anomalías estructurales. Praveena y Prasanna Devi (2024) refuerzan

que la preparación es "esencial para remover valores atípicos, ver patrones y comprender estacionalidad".

La síntesis establece un principio operativo: Prophet reduce barreras de entrada en calidad de datos comparado con métodos clásicos, pero no las elimina. La disponibilidad de al menos dos años de historia consistente y limpieza básica de anomalías extremas constituyen precondiciones para que el modelo entregue valor en contextos de retail.

### ***Capacidad de Modelado: Estacionalidades y Variables Exógenas***

**Modelado de Estacionalidades Múltiples.** Taylor y Letham (2018) diseñaron Prophet para manejar series con múltiples patrones estacionales superpuestos, característica que Kwarteng y Andreevich (2024) identifican como ideal para retail. Esta capacidad responde a que las ventas minoristas exhiben ciclos en diferentes escalas temporales. Barón y Carrascal (2024) documentan que "los datos de ventas de productos minoristas contienen múltiples ciclos estacionales de diferentes duraciones", ejemplificando con cerveza que muestra patrones semanales (altas en fines de semana) y anuales (incrementos en verano) simultáneamente.

La implementación técnica se basa en series de Fourier. Zhao y Zhang (2020) explican que el modelo se compone como  $y(t) = g(t) + s(t) + h(t) + \varepsilon$ , donde  $s(t)$  captura periodicidades mediante combinaciones de senos y cosenos. Kwarteng y Andreevich (2024) detallan que este enfoque permite capturar no solo frecuencias dominantes sino también armónicos, representando estacionalidades irregulares como ocurre cuando picos de venta no se distribuyen uniformemente. Gärtner et al. (2024) confirman el uso de transformación de Fourier sobre frecuencias mensuales y semanales con coeficientes estimados mediante penalización Lasso para prevenir sobreajuste.

Mejía y Aguilar (2024) documentan evidencia empírica: tres categorías de productos exhiben "comportamiento muy similar en la demanda promedio de ventas de los días de la semana", con picos durante fines de semana y niveles mínimos en días laborables excepto viernes, donde la demanda anticipa el fin de semana. Esta regularidad semanal se superpone con patrones mensuales y anuales que Prophet desagrega individualmente, permitiendo a stakeholders comprender qué proporción de variabilidad se debe a cada fuente estacional.

**Incorporación de Promociones y Eventos Especiales.** La capacidad de integrar eventos como variables exógenas constituye otro diferenciador crítico. Barón y Carrascal (2024) destacan "la importancia de considerar el impacto de las vacaciones y días feriados dentro de un año laboral, ya que estos eventos pueden tener efectos significativos en los patrones de consumo". Chiroque Huamanchumo (2025) implementó esta funcionalidad incorporando días festivos como factor externo que afecta ventas, validando información de festividades mediante triangulación de tres fuentes para asegurar precisión.

Taylor y Letham (2018) explican que el modelo permite al analista "proporcionar una lista personalizada de eventos pasados y futuros, identificados por nombre de evento o festivo" (p. 42), asumiendo que efectos de festividades son independientes entre sí. Esta flexibilidad resulta fundamental en retail donde eventos comerciales varían por geografía y cultura. Zhao y Zhang (2020) documentan aplicación en e-commerce chino, donde "según las características de ventas de e-commerce, fechas especiales como 'Six One Eight', 'Double Eleven' y 'Double Twelve' se añaden al término de festividades  $h(t)$ " del modelo.

La implementación técnica permite configurar ventanas de influencia. Liço et al. (2021) reportan que establecieron "la ventana inferior en -1. Esto dio más peso al día antes del festivo", reconociendo que en retail las compras anticipadas a festividades modifican patrones de

demanda. Phalachandra et al. (2023) confirman que "Facebook Prophet puede modificar pronósticos utilizando la característica de festividades cuando un día festivo o evento importante puede impactar la predicción", citando festivales como Dusshera y Diwali en India donde una porción significativa de la población adquiere productos masivamente.

El impacto en precisión es medible. Ensafi et al. (2022) reportan que incorporar efectos de festividades redujo RMSE de 194.93 a 167.29 y disminuyó MAPE 4 puntos porcentuales. Chang et al. (2025) confirman que "los resultados demuestran que incorporar festividades mejora la precisión de pronóstico en las nueve rutas" analizadas de transporte de mercancías. Sin embargo, Barón y Carrascal (2024) advierten que "hay una leve mejora en algunas métricas con la inclusión de feriados y vacaciones", sugiriendo que el impacto depende de qué tan estructuralmente significativos sean estos eventos para el producto específico. En su caso, concluyeron que "la incorporación de feriados y vacaciones en Prophet no ha mostrado una mejora significativa... Esto podría sugerir que los feriados y vacaciones no introducen variaciones suficientemente significativas en los datos" analizados.

**Detección Automática de Changepoints.** Los changepoints o puntos de cambio representan momentos donde la tendencia de ventas se altera significativamente. Taylor y Letham (2018) incorporaron esta funcionalidad al modelo de crecimiento, "definiendo explícitamente changepoints donde la tasa de crecimiento puede cambiar" (p. 40). Phalachandra et al. (2023) destacan que Prophet "incorpora la idea innovadora de que la tendencia de crecimiento puede alterarse en ciertos changepoints... Los changepoints pueden determinarse manualmente o automáticamente por Prophet".

Esta capacidad resulta crítica para eventos disruptivos. Naskinova et al. (2024) señalan que "Prophet puede gestionar changepoints, que son momentos en la serie temporal cuando la

tendencia cambia. El modelo automáticamente identifica estos changepoints y se ajusta a ellos, mejorando así su capacidad de alinearse con cambios en los datos". La pandemia COVID-19 proporcionó un caso extremo para validar esta funcionalidad. Žunić et al. (2021) demostraron que "el análisis de COVID-19 prueba que el modelo de pronóstico propuesto puede lidiar bien con cambios inesperados", aunque Panay et al. (2021) aclaran que "nuestro modelo no puede predecir comportamiento generado por causas externas (por ejemplo, COVID-19), pero puede estimar ventas esperadas para el período de cierre de tienda para estimar pérdidas".

Chiroque Huamanchumo (2025) documenta aplicación práctica en restaurante peruano donde ventas incrementaron abruptamente en 2020 por inicio de pandemia. Reporta que "al incorporar la fecha especial en el análisis, el modelo la reconoce y ajusta sus cálculos para evitar que influya en la proyección de los datos futuros, mejorando así la precisión y haciéndolo más confiable". La configuración del parámetro `changepoint_prior_scale` controla sensibilidad: valores altos permiten detectar más cambios pero incrementan riesgo de sobreajuste, mientras valores bajos hacen el modelo más conservador.

La síntesis de estas tres capacidades (estacionalidades múltiples, eventos exógenos y changepoints) configura el valor distintivo de Prophet: permite modelar la complejidad inherente de series de retail sin requerir expertise estadístico avanzado, transformando conocimiento del negocio en especificaciones técnicas mediante interfaces intuitivas.

### ***Interpretabilidad y Facilidad de Integración en BI***

La utilidad de un modelo predictivo en inteligencia de negocios trasciende su precisión numérica: debe generar confianza en quienes toman decisiones y facilitar su integración en flujos operativos. Prophet fue diseñado con estos criterios, priorizando explicabilidad y accesibilidad

por sobre complejidad algorítmica, lo cual tiene consecuencias prácticas tangibles cuando analistas de negocio, no científicos de datos, son los usuarios finales.

**Descomposición Modular y Explicabilidad Nativa.** Prophet descompone series temporales en componentes interpretables automáticamente. Taylor y Letham (2018) señalan que "el modelo descomponible nos permite observar cada componente del pronóstico por separado" (p. 43), funcionalidad que Gärtner et al. (2024) documentan operativamente: "el pipeline generó gráficos para cada producto visualizando la serie temporal descompuesta en estacionalidad y tendencia para permitir comprensión de los datos por parte del cliente". Esta descomposición permite identificar qué proporción de ventas proyectadas se debe a tendencia de largo plazo, cuánto responde a patrones semanales y qué impacto tienen eventos específicos.

Barrera y Gallego (2025) subrayan que "Prophet permite visualizar gráficamente la descomposición de la serie de datos en tendencia y estacionalidad, lo que facilita la interpretación de los resultados y la toma de decisiones". Esta transparencia contrasta con modelos de caja negra como redes neuronales o gradient boosting, donde la contribución de variables requiere técnicas post-hoc complejas como SHAP values. En Prophet, la explicabilidad es inherente a su arquitectura. La visualización también facilita diagnóstico: cuando un pronóstico resulta inesperado, el analista puede inspeccionar si la anomalía proviene de cambio de tendencia, variación estacional atípica o evento mal especificado.

**Facilidad de Uso para Analistas sin Expertise Estadístico.** Kwarteng y Andreevich (2024) caracterizan a Prophet como "amigable para el usuario, requiriendo preprocesamiento mínimo de datos", eliminando barreras de transformaciones complejas o selección manual de parámetros. Angelo et al. (2023) refuerzan que es "ideal para pronóstico de series temporales que

no requiere conocimiento profundo de modelos estadísticos", permitiendo que profesionales con formación en negocios implementen sistemas de forecasting robustos.

Taylor y Letham (2018) explicitan esta filosofía: "en la especificación del modelo Prophet existen varios lugares donde los analistas pueden alterar el modelo para aplicar su experiencia sin requerir ninguna comprensión de las estadísticas subyacentes" (p. 44). Este enfoque de "analista en el circuito" reconoce que el conocimiento de negocio sobre eventos o cambios estructurales es información valiosa incorporable sin exigir expertise estadístico avanzado. Hasan et al. (2022) documentan que "el modelo facilita la inclusión de componentes estacionales personalizados", ejemplificando el balance entre automatización y control: configuraciones por defecto sensatas funcionan sin ajustes, pero parámetros clave son accesibles para refinamiento.

**Integración Operativa en Sistemas de BI.** La adopción en ambientes de producción se facilita por su arquitectura en Python y R, lenguajes soportados en plataformas modernas de BI. Gärtner et al. (2024) documentan integración con dashboards interactivos que "permiten al cliente establecer parámetros para predicción y visualizar curvas de ventas y pronósticos directamente en el tablero". Esta integración requiere re-entrenamiento periódico automático, funcionalidad que Prophet facilita mediante rapidez de ajuste. Žunić et al. (2020) destacan esta ventaja en contextos con cientos de SKUs, señalando que permite "forecasting a escala" sin intervención manual producto por producto.

La capacidad de exportar componentes desagregados resulta estratégica: gráficos de tendencia, estacionalidad y efectos de eventos se integran en reportes ejecutivos, transformando el forecasting en herramienta de comunicación que alinea expectativas entre áreas comerciales,

logística y finanzas. Barrera y Gallego (2025) confirman que esta "interpretación de los resultados" facilita "la toma de decisiones basada en estas proyecciones".

La síntesis configura a Prophet como herramienta adecuada para organizaciones que buscan democratizar capacidades analíticas sin exigir que cada analista se convierta en especialista en series temporales. Esta accesibilidad determina si un modelo permanece confinado a equipos técnicos o se convierte en práctica estándar distribuida organizacionalmente.

## **Limitaciones y Desafíos Operativos**

### ***Limitaciones con Características de Datos***

Si bien Prophet demuestra fortalezas notables en contextos con datos de calidad y patrones estacionales definidos, enfrenta desafíos significativos cuando las series temporales exhiben características estructurales problemáticas. Estos desafíos no invalidan el modelo, pero establecen fronteras de aplicabilidad que deben reconocerse explícitamente para evitar expectativas irrealistas sobre su desempeño.

**Demanda Intermitente y Alta Variabilidad.** La demanda intermitente, caracterizada por largos períodos de ventas nulas intercalados con transacciones esporádicas, representa un escenario particularmente desafiante. Mejía y Aguilar (2024) documentan que productos en el Cluster 0, caracterizados por "alta intermitencia", lograron los resultados más bajos "debido a la recurrencia de demanda nula". Esta dificultad es estructural: Prophet estima componentes de tendencia y estacionalidad asumiendo continuidad subyacente en los patrones, suposición que se viola cuando las ventas son fundamentalmente esporádicas. Žunić et al. (2021) confirman que "los resultados confirman el dominio del algoritmo Prophet de Facebook para los ítems más importantes. Al reducir la importancia de los ítems, el dominio de Prophet sobre otros algoritmos

decrece", reflejando que productos de baja rotación no se benefician de las fortalezas del modelo en captura de estacionalidad.

Por otra parte, de la intermitencia, Prophet exhibe dificultades para capturar valores extremos con precisión. Panay et al. (2021) observan que "nuestro modelo no tiene problema detectando los picos y valles de los valores reales, aunque no alcanza los mismos valores superiores e inferiores", indicando tendencia a suavizar extremos. Hasan et al. (2022) reportan que "notamos que Facebook Prophet da algunos valores negativos... y no puede capturar los valores más altos", requiriendo correcciones post-hoc. Vargas-Forero et al. (2024) documentan que "en general, los tres métodos tienden a arrojar predicciones subestimadas" cuando la demanda aumenta significativamente, mientras Fredén y Larsson (2020) especifican que aunque "Facebook Prophet modeló exitosamente los efectos de festividades... la magnitud de cada pico en ventas no fue predicha con precisión".

**Inconsistencia y Ruido Estructural.** Perera et al. (2024) advierten que "cuando los datos incluyen varias irregularidades dentro del dataset debido a picos repentinos de demanda, escasez de recursos, errores de entrada de datos, pandemia y crisis económica, etc., reduce la calidad y confiabilidad de los datos y finalmente afecta la precisión del pronóstico". Aunque Prophet tolera cierto nivel de ruido mediante su formulación bayesiana, irregularidades masivas degradan su capacidad de identificar patrones genuinos. Praveena y Prasanna Devi (2024) señalan que anomalías estructurales requieren tratamiento previo mediante técnicas especializadas como STL decomposition para restaurar patrones identificables, reconociendo que la robustez nativa del modelo tiene límites operativos que deben gestionarse activamente. Gärtner et al. (2024) refuerzan que productos con historial corto "condujeron a errores más

elevados", problema agravado cuando ese historial incluye múltiples períodos anómalos sin contexto suficiente para distinguir ruido de señal.

### ***Factores Externos No Capturados***

Prophet captura tendencias, estacionalidades y eventos predefinidos, pero su arquitectura presenta limitaciones cuando factores externos críticos no están disponibles como variables o no pueden modelarse mediante su estructura aditiva. Estas limitaciones son especialmente relevantes en retail, donde decisiones de negocio y condiciones del mercado influyen en ventas de formas que trascienden patrones históricos recurrentes.

**Quiebres de Inventario (Stockouts) no Registrados.** Los stockouts constituyen uno de los factores distorsionadores más problemáticos. Cuando un producto se agota, las ventas registradas son cero no porque la demanda sea nula, sino porque la oferta fue insuficiente. Gärtner et al. (2024) documentan que "los datos recolectados en el sistema ERP fueron cifras de ventas. Datos sobre eventos raros de desabastecimiento o entregas retrasadas no se recolectan, pero podrían influir en la relevancia práctica. Con eso, los datos pueden no coincidir con la demanda real". Esta discrepancia entre ventas observadas y demanda latente sesga sistemáticamente las predicciones hacia abajo.

Perera et al. (2024) reconocen este desafío al admitir que "a pesar de las fortalezas de nuestro análisis, persisten algunas limitaciones... métodos alternativos podrían capturar más efectivamente eventos significativos como grandes interrupciones de suministro". La dificultad radica en que ajustar por stockouts requiere información que típicamente no se registra: cuántos clientes buscaron el producto y no lo encontraron, cuánta demanda se trasladó a sustitutos y cuánta se perdió. Sin estos datos, Prophet no puede diferenciar entre ausencia genuina de demanda y restricción artificial de oferta.

**Variables Contextuales no Incorporadas.** Múltiples variables influyen en ventas pero Prophet no las incorpora nativamente. Praveena y Prasanna Devi (2024) señalan que "algunos de ellos fallan en considerar el impacto de otras variables, como la demanda en otros nodos de la red". Variables como precios de competidores, campañas publicitarias, condiciones climáticas o indicadores macroeconómicos operan como impulsores pero quedan fuera del modelo estándar. Gärtner et al. (2024) sugieren que "investigaciones futuras pueden incluir características adicionales como gastos de marketing o información general como crecimiento del mercado, que podrían tener una influencia enorme en el desempeño del modelo".

### *Necesidad de Modelos Híbridos o Complementarios*

Estas limitaciones han motivado enfoques híbridos. Zhao y Zhang (2020) proponen "un modelo combinado basado en Prophet-SARIMA" para resolver limitaciones de modelos únicos. Iñiguez García (2025) desarrolla un "modelo híbrido Prophet-XGBoost" que "combina la capacidad de Prophet para modelar patrones temporales complejos con la flexibilidad y potencia de XGBoost" para incorporar múltiples variables exógenas.

Wellens et al. (2024) cuantifican esta dependencia: "la disponibilidad de entradas relacionadas con precio y promoción fue crucial para el desempeño de Prophet... Cuando estas variables estaban ausentes, la mejora de Prophet versus modelos tradicionales cayó" significativamente. Anusha y Maiti (2025) sintetizan que "Prophet ayudó a identificar tendencias de largo plazo... Sin embargo, sus limitaciones en capturar irregularidades de corto plazo requirieron que se combinara con métodos de aprendizaje automático".

La consecuencia práctica es que organizaciones que adopten Prophet deben evaluar qué factores externos son relevantes para su contexto y si poseen infraestructura de datos para

incorporarlos. La arquitectura permite agregar regresores personalizados, pero requiere inversión en ingeniería de datos y conocimiento del dominio.

**Barreras Técnicas y Organizacionales.** Más allá de las limitaciones algorítmicas intrínsecas, la implementación exitosa de Prophet en entornos de retail enfrenta desafíos de naturaleza técnica y organizacional que pueden determinar si el modelo se convierte en herramienta de uso generalizado o permanece confinado a proyectos piloto. Estas barreras no son insalvables, pero requieren inversiones específicas y decisiones estratégicas sobre infraestructura, escalabilidad y gestión del cambio organizacional.

**Desafíos de Escalabilidad en Portfolios Masivos.** Los retailers típicamente gestionan cientos o miles de SKUs simultáneamente, cada uno con sus propias características de demanda. Jha (2021) identifica que "la escalabilidad puede ser otro desafío para analizar un dataset grande. Un enfoque de aprendizaje por transferencia puede usarse junto con FB Prophet para mejorar la escalabilidad y manejar datasets grandes". Esta limitación surge porque Prophet, aunque rápido en términos relativos comparado con métodos bayesianos tradicionales, requiere entrenar un modelo independiente por cada serie temporal. Cuando el portfolio incluye miles de productos, el tiempo total de entrenamiento y la complejidad de gestionar múltiples modelos simultáneamente puede volverse prohibitivo.

Phalachandra et al. (2023) reconocen que "sin embargo, los hallazgos son específicos al dataset de tienda minorista usado y pueden no generalizarse a otros dominios de retail o datasets con características diferentes". Esta falta de generalización implica que no existe un modelo único "de fábrica" que funcione óptimamente para todos los productos: cada categoría o familia de productos puede requerir configuraciones específicas de parámetros (órdenes de Fourier,

sensibilidad a changepoints, ventanas de festividades), multiplicando la complejidad operativa cuando se opera a escala industrial.

**Requisitos de Infraestructura Técnica.** Prophet está implementado en Python y R, lo cual implica que las organizaciones deben contar con capacidades de despliegue en estos lenguajes. Gärtner et al. (2024) documentan una barrera específica: "el modelo entregó resultados prometedores, sin embargo, no pudo superar a los otros enfoques de deep learning. Asimismo, requiere rstan, lo cual fue desafiante de proveer en el ambiente productivo". Esta dependencia de librerías específicas y sus cadenas de dependencias puede generar fricciones en entornos corporativos con políticas restrictivas de software o infraestructura heredada donde la instalación de nuevas bibliotecas requiere aprobaciones extensas.

Negre et al. (2024) posicionan a Prophet como "un algoritmo con gran velocidad de ejecución y simplicidad al definir los hiperparámetros", ventaja que contrasta con la complejidad de infraestructura necesaria para modelos de deep learning. Sin embargo, esta simplicidad relativa no elimina completamente la barrera de entrada: organizaciones sin capacidades analíticas en Python/R enfrentan una curva de aprendizaje y costos de adopción que pueden ralentizar o impedir la implementación. La alternativa de contratar servicios externos o construir capacidades internas implica decisiones de inversión que deben justificarse mediante casos de negocio robustos.

**Limitaciones de Generalización Entre Contextos.** Un desafío frecuentemente subestimado es que configuraciones exitosas en un contexto no necesariamente se transfieren a otros. Phalachandra et al. (2023) advierten explícitamente sobre esta limitación de generalización, sugiriendo que cada implementación requiere validación específica. Esto tiene consecuencias para retailers que operan en múltiples geografías o segmentos: el modelo que

funciona óptimamente para productos de consumo masivo en mercados urbanos puede requerir reconfiguración sustancial para productos estacionales en mercados rurales o para categorías con dinámicas de demanda radicalmente diferentes.

La consecuencia operativa es que la adopción de Prophet no es una implementación única sino un proceso iterativo de experimentación, validación y refinamiento. Žunić et al. (2020) reconocen esta realidad al proponer un framework que incluye clasificación de productos según nivel esperado de precisión, admitiendo implícitamente que no todos los productos se benefician igualmente del modelo. Esta heterogeneidad de desempeño exige capacidades de monitoreo continuo y criterios claros para decidir cuándo Prophet es apropiado y cuándo deben considerarse métodos alternativos.

La síntesis de estas barreras técnicas y organizacionales subraya que la efectividad de Prophet no depende únicamente de sus méritos algorítmicos, sino de la capacidad institucional para desplegar, mantener y evolucionar sistemas de forecasting a escala. Organizaciones que subestimen estos desafíos corren el riesgo de implementaciones subóptimas que no materializan el valor potencial del modelo.

### **Síntesis: Condiciones Óptimas de Aplicación de Prophet en Retail**

El análisis exhaustivo de factores críticos de éxito y limitaciones operativas permite establecer con precisión bajo qué condiciones Prophet representa una solución estratégica óptima para la predicción de ventas en retail, y cuándo requiere complementos metodológicos o debe ceder lugar a enfoques alternativos. Esta síntesis no busca declarar superioridad o inferioridad absoluta, sino delimitar el espacio de aplicabilidad donde el modelo genera valor tangible y diferenciado.

### *Perfil de Aplicabilidad Óptima*

Prophet alcanza su máximo potencial cuando convergen simultáneamente varias condiciones favorables. La primera es la disponibilidad de datos históricos consistentes que abarquen al menos dos años completos, permitiendo que el modelo capture ciclos anuales y estacionalidades superpuestas con robustez estadística. Žunić et al. (2020) establecieron este umbral empíricamente y su validez ha sido confirmada por múltiples estudios posteriores. La segunda condición es la presencia de patrones estacionales claramente definidos y relativamente estables en el tiempo. Kwarteng y Andreevich (2024) sintetizan que "el estudio prueba que los modelos SARIMA sobresalen en manejar datasets con estacionalidad pronunciada... mientras que Prophet es más flexible en acomodar no linealidades y efectos de festividades", sugiriendo que la fortaleza distintiva de Prophet reside en contextos donde múltiples estacionalidades coexisten con eventos irregulares pero identificables.

La tercera condición favorable es que eventos externos relevantes (festividades, promociones, lanzamientos de producto) sean conocidos ex-ante y puedan documentarse sistemáticamente. Chang et al. (2025) demostraron que "incorporar festividades mejora la precisión de pronóstico en las nueve rutas" analizadas, pero esta mejora presupone que los eventos fueron identificados, fechados y codificados apropiadamente en el sistema. Cuando esta información no existe o es inconsistente, la ventaja competitiva de Prophet se erosiona. Finalmente, el contexto ideal incluye stakeholders que valoren la interpretabilidad y transparencia por sobre precisión marginal absoluta. Taylor y Letham (2018) diseñaron Prophet explícitamente para "analistas en el circuito", reconociendo que en muchos contextos de negocio, un modelo que explica claramente sus predicciones genera más confianza y utilidad que uno levemente más preciso pero opaco.

### *Escenarios Donde Prophet Enfrenta Limitaciones Críticas*

Inversamente, existen configuraciones donde Prophet no representa la solución óptima y requiere complementos o sustitución. Productos con demanda altamente intermitente, donde largos períodos de ventas nulas dominan la serie, erosionan la capacidad del modelo para estimar componentes estacionales de forma confiable. Mejía y Aguilar (2024) documentaron que estos productos "caracterizados por alta intermitencia" lograron los peores resultados precisamente porque la estructura aditiva de Prophet asume continuidad subyacente que no existe en estas series. En estos casos, métodos especializados para demanda intermitente (como Croston o TSB) pueden resultar más apropiados.

Contextos caracterizados por alta volatilidad y picos extremos también limitan la efectividad de Prophet. La tendencia del modelo a suavizar extremos, documentada por Panay et al. (2021) y Vargas-Forero et al. (2024), implica que sistemáticamente subestimaré demanda en períodos de crecimiento acelerado. Anusha y Maiti (2025) cuantifican esta limitación al reportar que "el modelo Prophet lucha con volatilidad de corto plazo, mostrando RMSE más alto y  $R^2$  más bajo que el ensamble", sugiriendo que cuando la dinámica de corto plazo domina sobre patrones estacionales, algoritmos de machine learning como XGBoost o modelos híbridos ofrecen ventajas tangibles.

La presencia de factores externos no capturables también constituye una frontera de aplicabilidad. Gärtner et al. (2024) identificaron que stockouts no registrados distorsionan la señal de demanda de forma que Prophet no puede corregir autónomamente, mientras que Wellens et al. (2024) demostraron que cuando variables críticas como precios o promociones están ausentes, "la mejora de Prophet versus modelos tradicionales cayó" drásticamente. Estas

situaciones exigen enfoques que incorporen explícitamente información exógena mediante regresores adicionales o modelos híbridos.

### ***Estrategias Pragmáticas de Implementación***

La síntesis de estos hallazgos sugiere que la adopción exitosa de Prophet en retail no debería plantearse como decisión binaria (adoptar o rechazar), sino como estrategia segmentada que reconoce heterogeneidad en el portfolio de productos. Žunić et al. (2020) ejemplifican este enfoque al clasificar productos según nivel esperado de precisión: aproximadamente 50% del portfolio podía pronosticarse con MAPE menor a 30% mensualmente, mientras 70% alcanzaba ese umbral trimestralmente. Crucialmente, este 40% de productos más predecibles representaban más del 80% del volumen financiero, implicando que la concentración de esfuerzos en productos de alta rotación y estacionalidad clara maximiza el retorno de la inversión en forecasting.

Zhao y Zhang (2020) proponen lógica complementaria mediante modelos híbridos que combinan las fortalezas de diferentes enfoques: "el modelo combinado Prophet-SARIMA" logró RMSE 1.508 puntos inferior a Prophet individual, demostrando que la hibridación sistemática puede superar limitaciones de modelos únicos. Iñiguez García (2025) extiende esta lógica al documentar que su modelo híbrido Prophet-XGBoost alcanzó MAE de 338 y MAPE de 8.75%, superando implementaciones individuales precisamente porque Prophet capturó estructura estacional mientras XGBoost incorporó relaciones no lineales y variables exógenas complejas.

La conclusión operativa es que Prophet constituye herramienta valiosa en el arsenal de forecasting de retail, particularmente efectiva para productos con estacionalidad pronunciada, eventos identificables y necesidad de interpretabilidad. Sin embargo, su adopción exitosa requiere reconocer explícitamente sus fronteras de aplicabilidad, complementarla estratégicamente con métodos alternativos donde sus limitaciones se manifiestan, e invertir en

infraestructura organizacional (datos, capacidades técnicas, cultura analítica) que permita materializar su valor potencial. La pregunta relevante no es si Prophet es superior en términos absolutos, sino cuándo y cómo su implementación genera ventajas competitivas tangibles en contextos específicos de retail.

**Contextualizar la Aplicabilidad de Prophet en el Mercado Colombiano, Considerando  
Patrones de Consumo Asociados a Quincenas, Festivos Nacionales y Temporadas  
Comerciales**

**Características Estructurales del Retail Colombiano**

El mercado retail colombiano presenta características distintivas que condicionan la aplicabilidad de metodologías de pronóstico desarrolladas en economías avanzadas. D'Andrea (2010) documenta que en América Latina "aún prevalecen estructuras sociales altamente dualistas" (p. 12), refiriéndose a la marcada desigualdad entre estratos. El mismo autor documenta mediante análisis de segmentación (ver D'Andrea, 2010, Figura 4, p. 96) que en Colombia los segmentos D y E representan el 52.9% de la población pero apenas el 12.8% del poder adquisitivo, generando patrones de consumo caracterizados por transacciones frecuentes de bajo monto.

D'Andrea (2010) identifica que el "vientre del mercado", es decir, consumidores de ingresos medios y bajos, representa aproximadamente el 60% de los consumidores regionales, concentrando más del 70% de su gasto en alimentación (p. 3). Esta concentración implica que modelos predictivos deben capturar dinámicas diferentes a las documentadas en literatura norteamericana y europea. El mismo autor observa que "los pequeños retailers continúan suministrando una porción significativa del mercado de bienes de consumo empacados" (p. 99), evidenciando la coexistencia de formatos modernos con comercio tradicional. Esta dualidad genera implicaciones metodológicas: D'Andrea (2010) explica que retailers exitosos "equilibran la necesidad de asequibilidad con las aspiraciones latentes de consumidores emergentes" (p. 87), reflejando que estos consumidores no priorizan el menor costo absoluto sino valor percibido y accesibilidad mediante crédito. El mismo autor documenta que estos consumidores "siguen un

comportamiento bastante racional y sofisticado mientras buscan reconciliar preferencias con su realidad económica" (D'Andrea, 2010, pág. 100).

Panay et al. (2021) aportan evidencia empírica analizando más de 3,000 tiendas en Chile, Colombia y Perú (p. 2), confirmando heterogeneidad estructural. Díaz de Astarloa et al. (2021) documentan que la penetración de internet alcanzaba el 67% en 2017 (p. 84), limitando disponibilidad de datos digitales y alcance del comercio electrónico. Mou et al. (2018) concluyen que "la gestión de tiendas retail en mercados en desarrollo debe recibir mayor atención investigativa" (p. 18), mientras Vargas-Forero et al. (2025) posicionan a Colombia como mercado emergente. Bălan (2021) confirma que la investigación académica muestra "la tendencia de investigadores a examinar en mayor medida mercados europeos, formatos de supermercado y operadores grandes" (p. 9), evidenciando sesgo hacia contextos diferentes al colombiano.

### ***Patrones de Consumo Asociados a Quincenas y Festividades Colombianas***

La modalidad de pago quincenal, donde los trabajadores reciben su salario en dos fechas del mes, constituye característica distintiva con implicaciones directas para pronóstico. Fildes et al. (2022) reconocen "efectos quincenales o mensuales (efectos de día de pago)" (p. 1294) como factores determinantes que generan picos de consumo predecibles cada quince días. En lugar de consolidar compras mensuales grandes, como es común en hogares de mayores ingresos, consumidores de estratos medios y bajos compran cantidades menores con mayor frecuencia. Este patrón responde directamente a la disponibilidad de efectivo tras cada quincena, implicando que modelos deben capturar no solo estacionalidad quincenal en volumen sino cambios en mix de productos: mayor margen post-pago versus menor precio unitario en segunda semana de quincena.

El calendario festivo colombiano introduce variaciones estacionales adicionales. Colombia celebra festividades particulares: Día de la Madre (mayo), Amor y Amistad (septiembre, equivalente local al Día de San Valentín), y temporada navideña extendida. Taylor y Letham (2018) reconocen que "los festivos varían por país y frecuentemente se basan en el calendario lunar" (p. 41), requiriendo "una lista personalizada de eventos pasados y futuros, identificados por el nombre único del evento o festivo" con "una columna para país que permita mantener una lista de festivos específicos por país además de festivos globales" (p. 41).

Los datos del Departamento Administrativo Nacional de Estadística evidencian el impacto cuantitativo: según el Boletín Técnico de la Encuesta Mensual de Comercio, diciembre de 2024 registró incremento del 6.5% en ventas nominales para grandes almacenes e hipermercados minoristas y del 17.1% en comercio electrónico respecto al mismo mes del año anterior (DANE, 2025), mientras enero de 2024 mostró contracción del 3.9% en ventas reales del comercio minorista (DANE, 2024), patrón post-festivo cuando hogares ajustan consumo tras gastos decembrinos. Fredén y Larsson (2020) confirman que "la temporada navideña fue donde los modelos tuvieron menos éxito, esto fue debido a las mayores fluctuaciones en ventas durante este período, los comportamientos de cliente cambiados, y la cantidad mínima de datos existentes representando este período" (p. 46), estableciendo que modelar estos efectos determina utilidad para planeación operativa.

### ***Desafíos Específicos para Forecasting en Colombia***

La implementación de sistemas de pronóstico enfrenta desafíos estructurales que condicionan la selección de metodologías predictivas. La fragmentación del mercado constituye barrera primaria. El patrón de compras frecuentes de bajo monto genera series con mayor volatilidad diaria, intermitencia elevada en SKUs individuales, y sensibilidad a eventos

microlocales. La heterogeneidad entre formatos, desde hipermercados modernos hasta tiendas de barrio tradicionales, complica modelos únicos aplicables a todo el mercado.

Panay et al. (2021) establecen que se requieren "al menos cuatro años de datos" (p. 16) para modelado confiable, restricción significativa para establecimientos nuevos, particularmente en formatos de conveniencia y comercio electrónico. Los mismos autores documentan que "tiendas en zonas turísticas cambian drásticamente su comportamiento durante períodos vacacionales comparado con el resto del año... durante períodos regulares tienen valores bajos y casi siempre cero para los indicadores. Cuando comienza el período de festivos, estos indicadores aumentan, a veces incluso excediendo aquellos de tiendas en grandes ciudades. Hemos observado que nuestro modelo no es capaz de predecir este tipo de comportamiento" (p. 16), evidenciando limitaciones incluso con datos suficientes.

La calidad de datos emerge como factor crítico. Aidoo-Anderson et al. (2025) identifican que "la información incorrecta e indisponibilidad de datos de departamentos clave en la organización es un obstáculo importante al proceso de pronóstico" (p. 13), refiriéndose a errores de captura, transacciones no registradas, o desincronización entre sistemas de punto de venta e inventario. Chiroque Huamanchumo (2025) documenta "duplicidad de datos ya que algunos productos tenían códigos compartidos, esto debido a que durante los tres años de análisis los productos han variado de nombre o han sido registrados dos veces" (p. 23), donde un mismo SKU se asignó a productos diferentes. Fildes et al. (2022) cuantifican que la intermitencia, definida como días sin ventas registradas para un producto específico, alcanza "alrededor del 70%" (p. 1311) en datos diarios a nivel producto-tienda, complicando modelado granular dado que métodos tradicionales como ARIMA requieren series relativamente continuas.

Las limitaciones de recursos en pequeñas y medianas empresas agravan estos desafíos. Mirza et al. (2025) reportan que "el 73% no contaba con recursos financieros" (p. 4) para invertir en sistemas analíticos, reflejando que presupuestos limitados fuerzan a pymes a priorizar inversiones operativas sobre capacidades analíticas. Aidoo-Anderson et al. (2025) confirman que "organizaciones pequeñas y medianas debido a su tamaño no tienen el lujo de invertir en procesos (tecnología o software) que pueden no agregar valor significativo a su pronóstico" (p. 13). Gimeno-Arias et al. (2024) observan que "el proceso ha sido más lento en pymes debido a las barreras a la digitalización que enfrentan, incluyendo recursos financieros y humanos limitados, resistencia interna al cambio" (p. 3), generando asimetría competitiva donde retailers grandes contratan equipos especializados mientras pymes dependen de pronósticos manuales.

### ***Oportunidades de Prophet en el Contexto Colombiano***

Las características técnicas de Prophet presentan alineación favorable con los desafíos identificados, posicionándolo como herramienta viable para retailers de diversos tamaños. Esta alineación abarca capacidades técnicas de modelado y ventajas operativas que reducen barreras de implementación.

**Capacidades Técnicas de Modelado.** Prophet permite incorporar estacionalidades múltiples mediante series de Fourier, funciones matemáticas que descomponen patrones complejos en combinaciones de ondas sinusoidales simples, posibilitando modelar ciclos quincenales además de estacionalidades convencionales. Taylor y Letham (2018) explicitan que el modelo "aproxima efectos estacionales suaves arbitrarios" mediante "series de Fourier estándar" donde "podemos especificar el período regular  $P$  que esperamos que la serie temporal tenga (por ejemplo,  $P = 365.25$  para datos anuales o  $P = 7$  para datos semanales)" (p. 41). Esta flexibilidad habilita representar ciclos de pago configurando  $P = 15$  sin modificaciones

algorítmicas: el modelo ajusta automáticamente coeficientes de Fourier apropiados. Naskinova et al. (2024) destacan que "el modelo facilita la inclusión de componentes estacionales personalizados, otorgándole flexibilidad y adaptabilidad" (p. 9), contrastando con ARIMA cuyo "desempeño puede deberse a suposiciones de estacionaridad y linealidad que no soportaban tal nivel de complejidad" (p. 18).

La incorporación de festividades constituye otra ventaja significativa. La funcionalidad opera mediante variables binarias que "asumen que los efectos de festivos son independientes" (Taylor & Letham, 2018, pág. 41), permitiendo que cada festivo contribuya aditivamente al pronóstico. Naskinova et al. (2024) destacan que "Prophet permite el ajuste de efectos de festivos, asegurando que el modelo pueda considerar los picos en demandas vinculados con los respectivos festivos o eventos" (p. 9). Barón y Carrascal (2024) refuerzan desde evidencia colombiana, enfatizando "la importancia de considerar el impacto de las vacaciones y días feriados dentro de un año laboral, ya que estos eventos pueden tener efectos significativos en los patrones de consumo" (p. 7). La capacidad de Prophet de capturar estos efectos sin requerir ingeniería manual de características reduce barreras técnicas, haciendo la herramienta más accesible para retailers sin equipos especializados.

**Ventajas Operativas para Implementación.** La robustez frente a datos imperfectos posiciona favorablemente a Prophet para entornos con limitaciones documentadas. Anusha y Maiti (2025) destacan que Prophet "puede manejar datos faltantes y valores atípicos de manera efectiva, haciéndolo una herramienta robusta para entornos retail donde los datos de ventas pueden no estar siempre limpios o completos" (p. 11). Esta capacidad deriva de formulación bayesiana donde observaciones faltantes se tratan como parámetros latentes a estimar, en lugar de requerir imputación explícita previa como métodos frecuentistas tradicionales. Agasi et al.

(2025) complementan, enfatizando que Prophet ofrece "la capacidad de generar predicciones precisas con tiempos de cómputo cortos, incluso con datos incompletos o 'sucios'" (p. 2), ventaja sobre redes neuronales que son "hambrientas de datos" y requieren datasets masivos bien curados. Naskinova et al. (2024) caracterizan a Prophet como "diseñado explícitamente para datos con tendencias estacionales sólidas y valores faltantes" (p. 9), priorizando robustez sobre precisión máxima en condiciones ideales.

La accesibilidad como software de código abierto constituye ventaja crítica donde limitaciones presupuestarias restringen adopción de soluciones comerciales costosas. Prophet está disponible sin costo en Python y R, eliminando barreras de licenciamiento. Anusha y Maiti (2025) resaltan que "la flexibilidad de Prophet, ajuste automático de parámetros e interpretabilidad lo hacen adecuado tanto para profesionales de negocios como para científicos de datos" (p. 11), destacando que no requiere experiencia profunda en estadística de series temporales. Esta accesibilidad contrasta con ARIMA, donde identificación de órdenes (p, d, q) requiere entendimiento de autocorrelación parcial y pruebas de raíz unitaria, conocimientos ausentes en analistas sin formación avanzada. Taylor y Letham (2018) diseñaron intencionalmente Prophet para "permitir ajuste intuitivo de parámetros sin conocimiento necesario de detalles del modelo subyacente" (p. 35), priorizando facilidad de uso. Naskinova et al. (2024) confirman "tiempos de ejecución bajos y resultados fácilmente interpretables" (p. 9), características valiosas donde analistas deben generar pronósticos para cientos de SKUs regularmente, facilitando iteración rápida y comunicación a stakeholders no técnicos.

## **Proponer Lineamientos Prácticos para la Adopción de Prophet en Sistemas de Inteligencia de Negocios Orientados a la Optimización de Inventarios y la Toma de Decisiones Estratégicas**

### **Prerrequisitos para la Adopción de Prophet en Retail**

El análisis de factores críticos de éxito y limitaciones desarrollado previamente permite derivar un conjunto de prerrequisitos operativos cuyo cumplimiento condiciona la viabilidad de implementar Prophet en contextos de retail. Estos prerrequisitos no constituyen recomendaciones abstractas sino condiciones verificables que las organizaciones deben evaluar antes de comprometer recursos en la adopción del modelo. Taylor y Letham (2018) diseñaron Prophet para democratizar el forecasting empresarial, pero esta accesibilidad no elimina requisitos mínimos de datos, infraestructura y capacidades organizacionales que determinan si la implementación generará valor o frustrará expectativas.

Los prerrequisitos se organizan en tres categorías interdependientes. La primera categoría abarca requisitos de datos, donde Žunić et al. (2020) establecieron empíricamente que se necesitan al menos 24 meses de historia transaccional para estimar con robustez estadística los componentes de tendencia y estacionalidad; este umbral se extiende cuando se requiere backtesting riguroso, dado que los autores recomiendan ejecutar al menos 12 repeticiones con paso mensual para validar la estabilidad predictiva. Adicionalmente, Chang et al. (2025) demostraron que la documentación sistemática de eventos externos resulta determinante, ya que incorporar festividades mejora significativamente la precisión únicamente cuando dichos eventos han sido identificados, fechados y codificados apropiadamente en el sistema de información.

La segunda categoría comprende requisitos técnicos e infraestructurales. Fredén y Larsson (2020) documentan que la implementación requiere entornos Python con librerías

especializadas incluyendo Pandas, NumPy y Scikit-learn para preparación de datos y evaluación de modelos. Ensafi et al. (2022) enfatizan que los modelos pueden aplicarse a diferentes datasets ejecutando el preprocesamiento adecuado y ajustando hiperparámetros, lo cual presupone capacidad técnica para estas tareas. Naskinova et al. (2024) añaden que el monitoreo continuo constituye práctica esencial para mantener precisión en entornos dinámicos, requiriendo infraestructura que permita actualización y refrescamiento periódico de modelos conforme emergen nuevos datos o tendencias.

La tercera categoría involucra requisitos organizacionales y de capacidades humanas. Gärtner et al. (2024) documentaron que los usuarios requieren capacitación específica sobre operación del pipeline de pronóstico, recomendando además una fase piloto de aproximadamente seis meses para validar efectividad bajo condiciones reales antes de escalamiento. Aidoo-Anderson et al. (2025) refuerzan que la capacitación formal e informal para forecasters debe normalizarse como práctica organizacional, advirtiendo que la experiencia sin entrenamiento estructurado puede resultar contraproducente cuando genera sobreconfianza en juicios no fundamentados. Finalmente, Taylor y Letham (2018) concibieron Prophet para analistas que, sin formación estadística avanzada, posean conocimiento sustantivo del dominio comercial, configurando un perfil híbrido que combina competencia técnica básica con expertise en el negocio.

### **Tabla 3**

#### *Prerrequisitos para Adopción de Prophet en Retail*

Categoría	Prerrequisito	Umbral/Criterio	Fuente
Datos	historia transaccional mínima	$\geq 24$ meses continuos	Žunić et al. (2020)

Categoría	Prerrequisito	Umbral/Criterio	Fuente
Datos	capacidad de backtesting	$\geq 12$ iteraciones mensuales	Žunić et al. (2020)
Datos	documentación de eventos	Festividades y promociones codificadas	Chang et al. (2025)
Datos	productos con demanda regular	Excluir alta intermitencia	Mejía & Aguilar (2024)
Técnico	entorno de programación	Python con Pandas, NumPy, Scikit-learn	Fredén & Larsson (2020)
Técnico	capacidad de procesamiento	Limpieza, transformación, calibración	Ensafi et al. (2022)
Técnico	infraestructura de monitoreo	Actualización periódica de modelos	Naskinova et al. (2024)
Organizacional	capacitación de usuarios	Entrenamiento formal en pipeline	Gärtner et al. (2024)
Organizacional	fase piloto	~6 meses antes de escalamiento	Gärtner et al. (2024)
Organizacional	perfil de analistas	Conocimiento de dominio + técnica básica	Taylor & Letham (2018)

La evaluación de estos prerrequisitos debe realizarse con honestidad organizacional. Cumplir parcialmente las condiciones de datos pero carecer de capacidades técnicas, o disponer de infraestructura sofisticada sin analistas con conocimiento del negocio, comprometerá los resultados independientemente de las virtudes algorítmicas del modelo. La adopción exitosa requiere convergencia de las tres categorías, no excelencia en una sola dimensión.

## Marco de Decisión para Selección de Enfoque Predictivo

La heterogeneidad inherente a los portafolios de productos en retail impide que un único modelo de forecasting resulte universalmente óptimo. Žunić et al. (2021) demostraron que Prophet domina consistentemente para ítems de alta rotación con historiales extensos, mientras que su ventaja se diluye progresivamente al reducirse la importancia y frecuencia de los productos analizados. Esta evidencia fundamenta la necesidad de un marco decisional que oriente la selección del enfoque predictivo según las características específicas del contexto, evitando tanto la adopción indiscriminada de Prophet como su descarte prematuro en escenarios donde genuinamente aporta valor.

El primer criterio diferenciador es la naturaleza de la demanda. Productos con ventas regulares y patrones estacionales identificables constituyen el escenario óptimo para Prophet, particularmente cuando coexisten múltiples estacionalidades con eventos comerciales documentables. En contraste, Mejía y Aguilar (2024) evidenciaron que productos caracterizados por alta intermitencia obtienen resultados deficientes debido a que la estructura aditiva del modelo asume continuidad subyacente inexistente en series dominadas por ceros; para estos casos, métodos especializados en demanda esporádica resultan más apropiados. Gärtner et al. (2024) añaden que incluso productos con demanda regular pero historiales cortos pueden no beneficiarse del modelo, ya que bajo estas condiciones Prophet no supera consistentemente al estimador naive.

El segundo criterio involucra la dinámica temporal predominante. Cuando los patrones estacionales de largo plazo dominan sobre fluctuaciones de corto plazo, Prophet captura eficazmente la estructura subyacente. Sin embargo, Anusha y Maiti (2025) documentaron que el modelo presenta limitaciones ante volatilidad de corto plazo, exhibiendo errores superiores

comparado con enfoques de ensamble. Similarmente, Wellens et al. (2024) demostraron que la ausencia de variables críticas como precios o promociones erosiona significativamente la ventaja de Prophet frente a alternativas tradicionales, indicando que contextos donde estas variables dominan requieren modelos capaces de incorporarlas explícitamente.

La respuesta a estas limitaciones no implica abandonar Prophet sino complementarlo estratégicamente. Zhao y Zhang (2020) propusieron modelos combinados Prophet-SARIMA que superan implementaciones individuales al capturar diferentes aspectos de la señal temporal. Iñiguez García (2025) extendió esta lógica mediante hibridación Prophet-XGBoost, alcanzando MAPE de 8.75% precisamente porque Prophet modeló la estructura estacional mientras XGBoost incorporó relaciones no lineales y variables exógenas. Kwarteng y Andreevich (2024) completan el panorama al identificar que SARIMA sobresale específicamente cuando la estacionalidad es pronunciada pero los efectos de eventos irregulares son mínimos, configurando un nicho donde Prophet no necesariamente aporta valor diferencial.

#### **Tabla 4**

##### *Marco de Decisión para Selección de Enfoque Predictivo*

Características del contexto	Enfoque recomendado	Justificación
Demanda regular + estacionalidad múltiple + eventos documentados + $\geq 24$ meses historia	Prophet individual	Escenario óptimo según diseño del modelo
Demanda regular + volatilidad corto plazo + variables exógenas relevantes	Prophet-XGBoost híbrido	Prophet captura estacionalidad, XGBoost incorpora no linealidades

Características del contexto	Enfoque recomendado	Justificación
Demanda regular + estacionalidad pronunciada + mínimos eventos irregulares	SARIMA o Prophet	Ambos competitivos, SARIMA más parsimonioso
Demanda intermitente (largos períodos sin ventas)	Métodos especializados (Croston, TSB)	Estructura aditiva de Prophet inadecuada
Historia corta (<12 meses) + demanda irregular	Naive o métodos simples	Insuficiente información para modelos complejos
Alta dependencia de precio/promociones sin datos disponibles	Modelos causales o juicio experto	Prophet requiere estas variables para ventaja competitiva

Este marco no pretende exhaustividad sino orientación práctica. Casos fronterizos requieren experimentación empírica mediante validación cruzada que compare alternativas bajo las condiciones específicas del dataset. La recomendación general es iniciar con Prophet en productos de alta rotación y estacionalidad clara, expandiendo gradualmente hacia segmentos más desafiantes únicamente tras validar desempeño satisfactorio en el núcleo del portafolio.

### **Lineamientos Operativos de Implementación**

Una vez verificados los prerrequisitos y seleccionado el enfoque predictivo apropiado, la implementación efectiva de Prophet requiere adherencia a lineamientos operativos que la literatura ha validado empíricamente. Estos lineamientos abarcan tres dimensiones: configuración técnica del modelo, validación mediante métricas apropiadas e integración con el ciclo operativo de inteligencia de negocios.

Respecto a la configuración técnica, la división de datos para entrenamiento y evaluación constituye el punto de partida. Abdelminaam et al. (2024) recomiendan particionar el dataset en 80% para entrenamiento y 20% para prueba, mientras Praveena y Prasanna Devi (2024) documentan implementaciones exitosas con división 70-30; la selección entre ambos esquemas depende del volumen de datos disponible, privilegiando mayor proporción de entrenamiento cuando el historial es limitado. Hasan et al. (2022) enfatizan que la configuración debe incorporar festividades y tendencias en múltiples escalas temporales, incluyendo patrones diarios, semanales, mensuales, trimestrales y anuales según corresponda al contexto comercial. Taylor y Letham (2018) añaden que los parámetros de suavizado  $\tau$  y  $\sigma$  permiten ajustar la flexibilidad de tendencia y la intensidad del componente estacional respectivamente, configuraciones que analistas con conocimiento del dominio pueden calibrar mediante inspección visual del ajuste histórico.

La validación del modelo demanda múltiples métricas complementarias. Adhikari y Agrawal (2013) establecen que considerar más de un criterio de evaluación permite obtener conocimiento razonable sobre magnitud, dirección y distribución del error de pronóstico. Naskinova et al. (2024) recomiendan específicamente la combinación de MAE, RMSE y  $R^2$  para comprender integralmente el desempeño predictivo. Hyndman y Koehler (2006) proponen MASE como métrica particularmente valiosa dado que valores inferiores a uno indican que el modelo supera al pronóstico naive, estableciendo un umbral mínimo de utilidad práctica. Žunić et al. (2020) complementan con umbrales operativos contextualizados: MAPE inferior al 15% en pronósticos trimestrales representa desempeño satisfactorio para productos de alta rotación, mientras que aproximadamente 70% del portafolio debería alcanzar MAPE menor al 30% para justificar la inversión en el sistema de forecasting.

La integración con el ciclo de inteligencia de negocios requiere definir horizontes de pronóstico y frecuencias de actualización apropiados. Fildes et al. (2022) documentan prácticas industriales donde los pronósticos se generan con horizonte de 22 o más semanas, desagregados a nivel diario y actualizados con la misma frecuencia para incorporar información reciente; adicionalmente, reportan que aproximadamente 5% de los pronósticos del sistema reciben ajustes manuales por parte de analistas, proporción que balancea automatización con juicio experto. Naskinova et al. (2024) subrayan que el monitoreo continuo permite detectar degradación del desempeño y activar reentrenamiento cuando las condiciones del mercado evolucionan. El impacto operacional de implementaciones exitosas es cuantificable: Wellens et al. (2024) documentan mejoras de 0.73% en nivel de servicio, reducción de 12.47% en costos de inventario y disminución superior al 30% en el efecto bullwhip, demostrando que la precisión predictiva se traduce en beneficios tangibles para la gestión de la cadena de suministro.

**Tabla 5**

*Lineamientos Operativos para Implementación de Prophet*

Dimensión	Lineamiento	Especificación	Fuente
Configuración	División de datos	70-30 o 80-20 según volumen disponible	Praveena & Prasanna Devi (2024); AbdElminaam et al. (2024)
	Incorporación de estacionalidades	Diaria, semanal, mensual, trimestral, anual	Hasan et al. (2021)

Dimensión	Lineamiento	Especificación	Fuente
Configuración	Calibración de parámetros	$\tau$ (flexibilidad tendencia) y $\sigma$ (intensidad estacional)	Taylor & Letham (2018)
Validación	Métricas múltiples	MAE, RMSE, $R^2$ , MAPE combinados	Naskinova et al. (2024); Adhikari & Agrawal (2013)
Validación	Umbral mínimo de utilidad	MASE < 1 (superar naive)	Hyndman & Koehler (2006)
Validación	Umbral satisfactorio	MAPE < 15% trimestral para alta rotación	Žunić et al. (2020)
Validación	Cobertura del portafolio	$\geq 70\%$ productos con MAPE < 30%	Žunić et al. (2020)
Integración BI	Horizonte de pronóstico	22+ semanas, desagregado a diario	Fildes et al. (2022)
Integración BI	Frecuencia de actualización	Diaria con monitoreo continuo	Fildes et al. (2022); Naskinova et al. (2024)
Integración BI	Ajustes manuales	$\sim 5\%$ de pronósticos revisados por analistas	Fildes et al. (2022)

La implementación de estos lineamientos debe adaptarse al contexto específico de cada organización. Retailers con operaciones en el mercado colombiano, caracterizado por ciclos de consumo asociados a quincenas y un calendario festivo particular, deberán configurar Prophet para capturar estas estacionalidades locales, aprovechando la flexibilidad del modelo para incorporar eventos específicos de la región. La capacidad técnica de Prophet para modelar múltiples patrones temporales simultáneos lo posiciona favorablemente para contextos donde la demanda exhibe la complejidad estructural documentada en mercados latinoamericanos.

## Conclusiones

La evidencia consolidada a través de la sistematización exhaustiva de 76 artículos académicos establece que Prophet demuestra aplicabilidad diferenciada en predicción de ventas retail mediante tres ventajas competitivas documentadas sistemáticamente. La revisión de literatura revela implementaciones exitosas desde aplicaciones masivas como el dataset M5 de Walmart con 3,049 productos hasta contextos especializados como supermercados europeos, validando la versatilidad sectorial del modelo (Praveena & Devi, 2024). La comparación tripartita confirma que Prophet supera consistentemente a ARIMA en interpretabilidad nativa y facilidad de integración BI, mientras mantiene competitividad estratégica con XGBoost en precisión predictiva según contexto operativo específico. Ensafi et al. (2022) documentan ventajas cuantificables: Prophet alcanza MAPE de 22.62% comparado con 28.98% de SARIMA, especialmente en series que incorporan efectos de festividades y estacionalidades pronunciadas.

Los factores críticos de éxito identificados establecen condiciones verificables para implementación exitosa. Žunić et al. (2020) demuestran empíricamente que se requieren mínimo 24 meses de datos históricos para estimación robusta de componentes estacionales, expandiéndose a 39 meses cuando se incorpora backtesting riguroso con 12 iteraciones mensuales. La contextualización al mercado colombiano revela oportunidades estratégicas específicas donde Prophet aborda directamente desafíos estructurales documentados. D'Andrea (2010) establece que los estratos socioeconómicos D y E representan 52.9% de la población colombiana pero concentran únicamente 12.8% del poder adquisitivo, generando patrones de compras frecuentes de bajo monto que Prophet puede modelar efectivamente mediante estacionalidades múltiples configurables. Los datos oficiales del DANE (2024) confirman impactos cuantitativos de temporadas comerciales: incrementos del 6.5% en grandes almacenes y

17.1% en comercio electrónico durante diciembre, variaciones que Prophet incorpora mediante configuración personalizada de festividades colombianas específicas.

Los lineamientos prácticos desarrollados organizan prerequisites en tres dimensiones interdependientes que condicionan la viabilidad organizacional. La dimensión de datos establece umbrales mínimos ( $\geq 24$  meses de historia, documentación codificada de eventos), la dimensión técnica especifica requerimientos infraestructurales (entornos Python, capacidades de procesamiento), y la dimensión organizacional define competencias necesarias (capacitación formal, analistas con conocimiento del dominio). Los lineamientos operativos precisan configuraciones técnicas validadas: divisiones train/test 70-30 o 80-20 según volumen disponible, incorporación de estacionalidades múltiples, validación mediante métricas combinadas donde MAPE  $< 15\%$  trimestral representa desempeño satisfactorio para productos de alta rotación.

En síntesis, la investigación confirma que Prophet mejora la precisión predictiva en retail mediante interpretabilidad superior y facilidad de integración BI, optimizando gestión de inventarios especialmente en contextos colombianos donde la capacidad de modelar ciclos quincenal, festividades específicas y robustez ante datos imperfectos posiciona al modelo como herramienta estratégica. Su valor diferencial radica en democratizar el acceso a forecasting avanzado con barreras técnicas reducidas, facilitando que organizaciones con capacidades analíticas emergentes materialicen ventajas competitivas tangibles mediante la transformación de datos históricos en conocimiento operacional accionable para optimización de inventarios y fortalecimiento de inteligencia de negocios.

## Recomendaciones

Las organizaciones retail deben implementar Prophet mediante estrategia de adopción gradual fundamentada en los prerequisites verificables desarrollados sistemáticamente. La implementación debe iniciarse evaluando tres dimensiones interdependientes: datos ( $\geq 24$  meses historia transaccional, documentación codificada de festividades), infraestructura técnica (entornos Python con librerías especializadas, capacidad de monitoreo continuo), y capacidades organizacionales (equipos con conocimiento del dominio, capacitación formal del pipeline). Žunić et al. (2020) confirman que la adopción por fases mediante pilotos de 6 meses en productos de alta rotación maximiza probabilidad de éxito antes del escalamiento operativo. Para contextos colombianos específicamente, las organizaciones deben configurar Prophet aprovechando su capacidad de modelar ciclos quincenal y festividades locales mediante el calendario comercial FENALCO, posicionando el modelo como herramienta estratégica donde la robustez ante datos imperfectos facilita adopción en mercados con limitaciones de calidad de información.

Las investigaciones futuras deben priorizar validación empírica con datasets colombianos reales que confirmen aplicabilidad regional de lineamientos operativos sistematizados. La colaboración academia-industria debe desarrollar estudios longitudinales sobre modelos híbridos Prophet-XGBoost que combinen capacidades estacionales con variables exógenas complejas. Adicionalmente, se requiere investigación específica sobre factores contextuales del retail latinoamericano, incluyendo efectos cuantificables de informalidad, fragmentación de mercado y patrones de pago quincenal en métricas de precisión predictiva, estableciendo benchmarks regionales para implementaciones futuras en contextos de recursos limitados.

### Referencias Bibliográficas

AbdElminaam, D., Mohamed, M., Khaled, S., Hany, F., Magdy, M., & Sherif, Y. (2024).

Leveraging Machine Learning for Accurate Store Sales Prediction: A Comparative Study. *International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)*, <https://doi.org/10.1109/miucc62295.2024.10783509>.

doi:<https://doi.org/10.48550/arXiv.2410.13773>

Agasi, A. A., Ahmad, G. N., & Buchdadi, A. D. (2025). Comparative study of Composite Stock

Price Index (JCI) prediction using the Autoregressive Integrated Moving Average (ARIMA) and Facebook Prophet methods. *Global Scientific and Academic Research Journal of Economics, Business and Management.*, 36-41. Obtenido de

<https://gsarpublishers.com/wp-content/uploads/2025/01/GSARJEEM172025-Gelary-script.pdf>

Aidoo-Anderson, A., Polychronakis, Y., & Sapountzis, S. (. (2025). Investigating demand

forecasting practices and challenges in Ghana's Manufacturing Pharmaceutical (MPharma) small and medium enterprises (SMEs): Insights and recommendations. *International Journal of Production Research*, 1-22.

doi:<https://doi.org/10.1080/00207543.2025.2508335>

Ali, Y., & Nakti, S. (2023). Sales Forecasting: A Comparison of Traditional and Modern Times-Series Forecasting Models on Sales Data with Seasonality.

Angelo, M. D., Fadhiilrahmana, I., & Purnama, Y. (2023). Comparative analysis of ARIMA and Prophet algorithms in Bitcoin price forecasting. *Procedia Computer Science*, 227, 490-499. doi:<https://doi.org/10.1016/j.procs.2023.10.550>

- Anusha, C., & Maiti, S. (2025). Optimizing Retail Inventory and Sales Through Advanced Time Series Forecasting Using Fine Tuned PrGB Regressor.  
doi:<https://doi.org/10.1109/ACCESS.2025.3605229>
- Asati, A. (2022). A Comparative Study On Forecasting Consumer Price Index Of India Amongst XGBoost, Theta, ARIMA, Prophet And LSTM Algorithms.  
doi:<https://doi.org/10.31219/osf.io/hyqsb>
- Astarloa, B., Mulder, N., Corcuera-Santamaría, S., Weck, W., Barreiros, L., Contreras Huerta, R., & Patiño, A. (2021). Post Pandemic Covid-19 Economic Recovery: Enabling Latin America and the Caribbean to Better Harness E-commerce and Digital Trade.  
doi:<https://doi.org/10.18235/0003436>
- Atanda, O. G., Abiodun, M. K., Lawrence, M. O., Adebisi, M. O., Awodoye, O. O., Adewumi, D., & Adebisi, A. A. (2024). Intelligent Sales Forecasting System Using ARIMA, SARIMA, and XGBOOST Models. *2024 International Conference on Science, Engineering and Business for Driving Sustainable Development Goals (SEB4SDG)*, 1-7.  
doi:<https://doi.org/10.1109/SEB4SDG60113.2024.10543666>
- Bălan, C. (2021). How Does Retail Engage Consumers in Sustainable Consumption? A Systematic Literature Review. doi:<https://doi.org/10.3390/su13010096>
- Baron, J. D. (2024). Modelo predictivo de ventas usando aprendizaje automático (Machine Learning) para pronosticar las ventas diarias de una empresa. Obtenido de <https://repository.unad.edu.co/handle/10596/62872>
- Barrera, A. F., & Gallego, F. A. (2025). *Desarrollo de un modelo basado en machine learning para pronosticar el número de usuarios de televisión por suscripción para el*

- departamento de Cundinamarca. UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS. Obtenido de <http://hdl.handle.net/11349/98202>*
- Bell, P. C. (2000). Forecasting demand variation when there are stockouts. *Springer Nature Link*.  
doi:<https://doi.org/10.1057/palgrave.jors.2600877>
- Chang, H., Yang, Z., & Zhang, Y. (2025). Forecasting daily freight flow in cold regions of China using the hybrid Prophet model considering the importance of festivals and epidemic prevention policy. *Research in Transportation Business & Management*, 59.  
doi:<https://doi.org/10.1016/j.rtbm.2025.101294>
- Chiroque, H. N. (2025). *Desarrollo de una aplicación de predicción usando machine learning para la planificación de compra de insumos en el restaurante El Nuevo Ferrocarril*. Chiclayo: UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO.
- Cordova-Buiza, F., Hernandez-Zuniga, K., Julca-Carrasco, K., & Huerta-Tantalean, L. N. (2022). Strategic Management of E-Commerce in Commercial Companies: A Systematic Review (2016 -2020). *European Conference on Innovation and Entrepreneurship*.  
doi:<https://doi.org/10.34190/ecie.17.1.344>
- D'Andrea, G. (2010). Latin American retail: where modernity blends with tradition. *The International Review of Retail, Distribution and Consumer Research*, 85-101.  
doi:<https://doi.org/10.1080/09593960903497864>
- D'Andrea, G., Silvestri, L., Costa, L., Fernandes, F., & Fossen, F. (2010). Spinning the Wheel of Retailing in Latin America. *International Studies of Management & Organization*, 52-73.  
doi:<https://doi.org/10.2753/IMO0020-8825400203>
- Dankorpo. (2024). Sales Forecasting for Retail Business using XGBoost Algorithm.  
doi:<https://doi.org/10.32996/jcsts>

- Datta, A., Dey, B. K., Bhuniya, S., Sangal, I., Mandal, B., Sarkar, M., . . . Ganguly, B. (2025). Adaptation of e-commerce retailing to enhance customer satisfaction within a dynamical system under transfer of risk. *Journal of Retailing and Consumer Services*. doi:<https://doi.org/10.1016/j.jretconser.2024.104129>
- Ensafi, S. H. (2022). Time-series forecasting of seasonal items sales using machine learning – A comparative analysis. *International Journal of Information Management Data Insights*, Vol. 2, Núm. 1, Artículo 100058. doi:<https://doi.org/10.1016/j.jjime.2022.100058>
- Ensafi, Y., Amin, S., Zhang, G., & Shah, B. (2022). Time-series forecasting of seasonal items sales using machine learning: A comparative analysis. *International Journal of Information Management Data*. doi:<https://doi.org/10.1016/j.jjime.2022.100058>
- Fildes, R., Ma, S., & Kolassa, S. (2022). Retail forecasting: Research and practice. doi:<https://doi.org/10.1016/j.ijforecast.2019.06.004>
- Fredén, D., & Larsson, H. (2020). *Forecasting Daily Supermarkets Sales with Machine Learning. Sweden Supermarkets*. STOCKHOLM: Royal Institute of Technology. Obtenido de <https://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-276483>
- Gärtner, T., Lippert, C., & Konigorski, S. (2024). Automated demand forecasting in small to medium-sized enterprises. *arXiv*. doi:<https://doi.org/10.48550/arXiv.2412.20420>
- Gimeno-Arias, F., Santos-Jaén, J. M., & González-Adalid, M. P. (2024). How are companies going to business digitalization? An explanation based on the implementation of e-commerce with data of SMEs. *Data in Brief*, 56. doi:<https://doi.org/10.1016/j.dib.2024.110788>

- Hasan, M. R., Kabir, M. A., Shuvro, R. A., & Das, P. (2022). A comparative study on forecasting of retail sales. *Cornell University*.  
doi:<https://doi.org/10.48550/arxiv.2203.06848>
- Hasan, M. R., Kabir, M. A., Shuvro, R. A., & Das, P. (2022). A Comparative Study on Forecasting of Retail Sales. *arXiv preprint*.  
doi:<https://doi.org/10.48550/arXiv.2203.06848>
- Iñiguez, G. A. (2025). *Modelo Híbrido Prophet/XGBoost para Predicción Demanda de Inventarios Retail Automotive Aftermarket*. Obtenido de  
<https://hdl.handle.net/11117/11596>
- Jha, B. K. (2021). Time Series Forecasting Model for Supermarket Sales using FB-Prophet. *Proceedings of the Fifth International Conference on Computing Methodologies and Communication*, 525-530. doi:<https://doi.org/10.1109/ICCMC51019.2021.9418033>
- Ji, S., Wang, X., & Zhao, W. e. (2019). An Application of a Three-Stage XGBoost-Based Model to Sales Forecasting of a Cross-Border E-Commerce Enterprise.  
doi:<https://doi.org/10.1155/2019/8503252>
- Kayikci, Y., Demir, S., Mangla, S. K., Subramanian, N., & Koc, B. (2022). Data-driven optimal dynamic pricing strategy for reducing perishable food waste at retailers. *Journal of Cleaner Production*, 344. doi:<https://doi.org/10.1016/j.jclepro.2022.131068>
- Kumar, L., Sharma, K., & Khedlekar, U. (2024). Dynamic pricing strategies for efficient inventory management with auto-correlative stochastic demand forecasting using exponential smoothing method. *Results in Control and Optimization*.  
doi:<https://doi.org/10.1016/j.rico.2024.100432>

- Kwarteng, S. B., & Andreevich, P. A. (2024). Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting. *Research & Development*, 110-120.  
doi:<https://doi.org/10.11648/j.rd.20240504.13>
- Li, M. (2025). Multisource Heterogeneous Data Fusion Methods Driven by Digital Twin on Basis of Prophet Algorithm. doi:<https://doi.org/10.1049/sfw2/5041019>
- Liço, L., Enesi, I., & Jaiswal, H. (2021). Predicting Customer Behavior Using Prophet Algorithm In A Real Time Series Dataset. *European Scientific Journal*.  
doi:<https://doi.org/10.19044/esj.2021.v17n25p10>
- Liu, B., Li, M., Ji, Z., Li, H., & Luo, J. (2024). Intelligent Productivity Transformation: Corporate Market Demand Forecasting With the Aid of an AI Virtual Assistant.  
doi:<https://doi.org/10.4018/joeuc.336284>
- Malik, S., Khan, M., Abid, M. K., & Aslam, N. (2024). Sales Forecasting Using Machine Learning Algorithm in the Retail Sector. *Journal of Computing & Biomedical Informatics*, 282–294. Obtenido de <https://www.jcbi.org/index.php/Main/article/view/370>
- Massaro, A., Panarese, A., Giannone, D., & Galiano, A. (2021). Augmented Data and XGBoost Improvement for Sales Forecasting in the Large-Scale Retail Sector. *Applied Sciences*.  
doi:<https://doi.org/10.3390/app11177793>
- Mehmood, U., Broderick, J., Davies, S., Bashir, A., & Rabie, K. (2024). Machine Learning-Based predictive inventory for a vending machine warehouse. *IEEE Internet of Things Magazine*. doi:<https://doi.org/10.1109/iotm.001.2300271>
- Mejía, S., & Aguilar, J. (2024). Demand forecasting, Machine learning, Feature engineering, Time series, Ensemble learning, Retail, Product clustering, LSTM, Random Forest, Linear Regression., (pág. 106). doi:<https://doi.org/10.1007/s00607-024-01320-y>

- Mirza, J., Ahmad, S., Khan, M., & Ali, R. (2025). Smart Sales Forecasting Machine Learning Models for Demand Prediction in Retail. *International Conference on Intelligent Data Communication Technologies*. doi:<https://doi.org/10.1109/IDCIOT64235.2025.10915120>
- Mohamad, A. F., Jasin, A. M., Asmat, A., Canda, R., Ismail, J., & Soom, A. B. (2023). Sales Analytics Dashboard with ARIMA and SARIMA Time Series Model. *IEEE Xplore*, 106-112. doi:<https://doi.org/10.1109/ISCAIE57739.2023.10165270>
- Mou, Robb, & DeHoratius. (2018). Retail store operations: Literature review and research directions. doi:<http://dx.doi.org/10.1016/j.ejor.2017.07.003>
- Naskinova, I., Kolev, M., & Lazarova, M. (2024). Forecasting Strategies in Retail: Utilizing Advanced Machine Learning Methods while Safeguarding Privacy. *Journal of Physics Conference Series*. doi:<https://doi.org/10.1088/1742-6596/2910/1/012008>
- Nasseri, Falatouri, Brandtner, & Darbanian. (2023). Applying Machine Learning in Retail Demand Prediction-A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning. doi:<https://doi.org/10.3390/>
- Nasseri, M., Falatouri, T., Brandtner, P., & Darbanian., F. (2023). Applying Machine Learning in Retail Demand Prediction-A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning. doi:<https://doi.org/10.3390/>
- Negre, P., Alonso, R. S., Prieto, J., García, Ó., & de-la-Fuente-Valentín, L. (2024). Prediction of footwear demand using Prophet and SARIMA. *ELSEVIER*. doi:<https://doi.org/10.1016/j.eswa.2024.124512>
- Olavarrieta, S., & Villena, M. G. (2014). Innovation and business research in Latin America: An overview. *Journal of Business Research*, 67, 489-497. doi:<https://doi.org/10.1016/J.JBUSRES.2013.11.005>

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., . . .

Hróbjartss, A. (2021). Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. doi:<https://doi.org/10.1016/j.gaceta.2021.04.006>

Panay, Baloian, Pino, Peñafie, Frez, Fuenzalida, . . . Zurita. (2021). Forecasting Key Retail Performance Indicators Using Interpretable Regression.

doi:<https://doi.org/10.3390/s21051874>

Perera, A. H., Talagala, P. D., Perera, H. N., & Thibbotuwawa, A. (2024). Enhancing Demand Forecasting in Food. *2024 9th International Conference on Information Technology Research (ICITR)*, 1-6. doi:10.1109/ICITR64794.2024.10857772

Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M., Barrow, D., Taieb, S., . . . De Baets. (2022). Forecasting: theory and practice. *International Journal of Forecasting*.

doi:<https://doi.org/10.1016/j.ijforecast.2021.11.001>

Phalachandra, Naik, Nukal, Singh, & Ranganath. (2023). Evaluating the Predictive Power of Prophet Model and LSTM Model in Retail Sales Forecasting.

doi:<https://doi.org/10.1109/indiscon58499.2023.10270146>

Praveena, & Devi, P. (2024). A Hybrid Deep Learning Based Deep Prophet Memory Neural Network Approach for Seasonal Items Demand Forecasting.

doi:<https://doi.org/10.12720/jait.15.6.735-747>

Reinartz, W., Wiegand, N., & Imschloss, M. (2018). The impact of digital transformation on the retailing value chain. doi:<https://doi.org/10.1016/j.ijresmar.2018.12.002>

Rios, J. H., & Vera, J. R. (2023). Dynamic pricing and inventory control for multiple products in a retail chain. *Computers & Industrial Engineering*.

doi:<https://doi.org/10.1016/j.cie.2023.109065>

- S, A., M, H., H, M., & A., M. (2024). Comparison of Deep Learning Algorithms for Retail Sales Forecasting. *ICCK Transactions on Intelligent Systematics*.  
doi:<https://doi.org/10.62762/TIS.2024.300700>
- Sandeep, V., Kandavel, N., R, S., Gowri, R., Thirumalai Murugan, R., & Zahid Hussain, J. (2025). Smart Sales Forecasting Machine Learning Models for Demand Prediction in Retail. *3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, 2139-2143.  
doi:<https://doi.org/10.1109/IDCIOT64235.2025.10915120>
- Sunaina, M., A, M., Monal, B. P., R, P., & TR, P. (2025). Retail Analysis and Inventory Management. doi:<https://doi.org/10.55041/ijssrem41644>
- Syntetos, A., Babai, Z., Boylan, J., Kolassa, S., & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*. doi:<https://doi.org/10.1016/j.ejor.2015.11.010>
- Taylor, S., & Letham, B. (2018). Forecasting at Scale.  
doi:<https://doi.org/10.1080/00031305.2017.1380080>
- V, S., N, K., Saivenkat, R., R, G., R, T. M., & J, Z. H. (2025). Smart Sales Forecasting Machine Learning Models for Demand Prediction in Retail. *IEEE Xplore*.  
doi:10.1109/IDCIOT64235.2025.10915120.
- Vargas-Forero, V. M., Manotas-Duque, D. F., & Trujillo, L. (2024). Comparative study of forecasting methods to predict the energy demand for the market of Colombia. *International Journal of Energy Economics and Policy*, 15,(1), 65-76.  
doi:<https://doi.org/10.32479/ijeeep.17528>

- Wellens, A. P., Boute, R. N., & Udenio, M. (2024). Simplifying tree-based methods for retail sales forecasting with explanatory variables. *European Journal of Operational Research*, 523-539. doi:<https://doi.org/10.1016/j.ejor.2023.10.039>
- Zanatti, M. M. (2018). History of retailing in Latin America. doi:<https://doi.org/10.4324/9781315560854-25>
- Zhao, & Zhang. (2020). Research on sales forecast based on Prophet-SARIMA combination model. doi:<https://doi.org/10.1088/1742-6596/1616/1/012069>
- Žunić, E., Korjenić, K., Delalić, S., & Šubara, Z. (2021). Comparison analysis of Facebook's Prophet, Amazon's DeepAR+ and CNN-QR algorithms for successful Real-World sales forecasting. *International Journal of Computer Science and Information Technology*, 67–84. doi:<https://doi.org/10.5121/ijcsit.2021.13205>
- Žunić, E., Korjenić, K., Hodžić, K., & Đonko, D. (2020). Application of Facebook's Prophet Algorithm for Successful Sales Forecasting Based on Real-world Data. doi:<https://doi.org/10.5121/ijcsit.2020.12203>