

Universidad de Belgrano



Facultad de Ciencias Económicas

**“Impacto de los métodos estadísticos en la precisión del pronóstico de
demanda en la industria textil”**

Tutor: Tapia, Gustavo

Alumna: Garcia Franco, Adriana

Maestría en Administración de Empresas

ID: P 000-19-5551

Agosto 2026

Resumen

El pronóstico de la demanda constituye un proceso fundamental para la planificación de la cadena de suministro, especialmente en la industria textil, donde la estacionalidad, la volatilidad del mercado y las variaciones del poder adquisitivo incrementan la complejidad de la toma de decisiones. Sin embargo, muchas empresas continúan utilizando métodos empíricos basados en hojas de cálculo y juicio experto, lo que limita la precisión de los pronósticos y afecta la planificación de la producción, las compras y los inventarios.

El presente trabajo analiza el impacto de los métodos estadísticos en la precisión del pronóstico de demanda mediante una investigación teórica, documental y comparativa de la literatura especializada. Para ello, se revisan estudios y casos de aplicación de metodologías como promedios móviles, suavización exponencial, Holt-Winters, ARIMA y técnicas de *machine learning*, comparando su desempeño mediante indicadores de precisión como MAPE, WAPE, MAE y RMSE.

Los resultados evidencian que la aplicación de métodos estadísticos mejora la precisión y confiabilidad de los pronósticos en comparación con los enfoques tradicionales. Sin embargo, la literatura demuestra que no existe un único modelo óptimo para todas las situaciones, ya que su desempeño depende de factores como la calidad de los datos, las características de la demanda y variables externas, entre ellas la estacionalidad, la volatilidad del mercado y las variaciones del poder adquisitivo (especialmente en un país como Argentina). En consecuencia, la adecuada selección e implementación de estas metodologías contribuye a optimizar la planificación de la producción, las compras y los inventarios, fortaleciendo la toma de decisiones en la cadena de suministro de la industria textil..

Palabras clave: pronóstico de demanda; métodos estadísticos; forecasting; industria textil; cadena de suministro; planificación de la demanda

Índice de contenido

1. Introducción	6
1.1. Contexto general de la industria textil (regional y nacional)	6
1.2. Entorno cambiante: poder adquisitivo, consumo y estacionalidad	7
1.3. Rol del demand planning y problemáticas actuales (planificación empírica, uso de Excel)	9
1.4. Planteamiento del problema y justificación del estudio	10
1.5. Objetivo general, hipótesis y objetivos específicos	12
1.6. Alcance y limitaciones	13
2. Marco Teórico.....	14
2.1. Fundamentos del pronóstico de demanda	14
2.1.1. Definiciones básicas	14
2.1.2. Diferencia entre demanda real y ventas (restricciones de supply).....	20
2.1.3. Relevancia del forecasting en cadenas de suministro textiles	23
2.2. Métodos estadísticos de pronóstico	28
2.2.1. Promedios móviles, suavización exponencial, Holt–Winters, ARIMA	31
2.2.2. Modelos causales y machine learning.....	38
2.2.3. Supuestos de aplicación y requisitos de datos	40
2.3. Variables críticas en el sector textil.....	44
2.3.1. Estacionalidad, lanzamientos vs. Básicos	45
2.3.2. Supuestos de uso y requisitos de entrada en industria textil	47
2.3.3. Segmentación de clientes, márgenes y poder adquisitivo como variable macroeconómica.....	48
2.4. Métricas de evaluación de precisión	50
2.4.1. MAPE, WAPE, MAE, RMSE y rangos de referencia	50
2.5. Industria textil y entorno VUCA.....	53
2.5.1. Implicancia de la volatilidad e incertidumbre	53
2.5.2. Rol de escenarios teóricos para evaluar robustez del forecast.....	54
2.6. Revisión de estudios previos	55
2.6.1. Casos relevantes en la industria textil (nacional e internacional).....	55
2.6.2. Resultados reportados: mejoras de precisión, lecciones aprendidas	57
3. Metodología	59
3.1. Tipo de investigación (Teórica, documental, exploratoria y comparativa)	59
3.2. Estrategia de revisión de literatura.....	59

3.3.	Variables de análisis.....	60
3.4.	Procedimiento de análisis.....	60
3.4.1.	Clasificación de métodos, sistematización de resultados, comparación de métricas	61
3.5.	Análisis de escenarios.....	63
3.5.1.	Consideración de estudios que evalúen entornos base, optimistas y pesimistas.....	63
3.6.	Criterios de evaluación (interpretación de mejoras en MAPE/WAPE y robustez de modelos en entornos VUCA).....	64
4.	Análisis y Discusión de Resultados de la Literatura.....	64
4.1.	Caracterización de los estudios analizados.....	65
4.2.	Problemáticas identificadas en la literatura.....	67
4.3.	Comparación de métodos de pronóstico identificados.....	74
4.4.	Variables y condiciones de análisis utilizadas en los estudios.....	77
4.5.	Impacto de los métodos estadísticos en la precisión del forecast.....	82
4.6.	Factores críticos que afectan el desempeño de los modelos.....	84
4.7.	Implicancias para la industria textil argentina.....	87
5.	Conclusiones.....	90
5.1.	Cumplimiento del objetivo general y principales hallazgos.....	90
5.2.	Cumplimiento de objetivos específicos.....	91
5.3.	Verificación de la hipótesis.....	93
5.4.	Beneficios de los usos del forecasting estadísticos.....	93
5.5.	Recomendaciones para empresas del sector textil.....	94
5.6.	Limitaciones del estudio y futuras líneas de investigación.....	95
6.	Bibliografía.....	96
7.	Anexos.....	99
7.1.	Cuadros comparativos de estudios revisados.....	99
7.2.	Glosario de términos.....	109

Índice de Figuras

Figura 1. Evolución del salario real promedio en Argentina (índice 1960=100) y tendencia utilizando el filtro Hodrick-Prescott, 1950-2006.	16
Figura 2. Relación entre el poder adquisitivo y la planificación de la demanda	49
Figura 3. Clasificación ABC de productos textiles según su participación en las ventas	87

Índice de Tablas

Tabla 1. Tipos de incertidumbre en la cadena de suministro.....	9
Tabla 2. Relación entre horizonte de pronóstico y toma de decisiones	17
Tabla 3. Principales métricas de evaluación de precisión del forecast	51
Tabla 4. Tipos de incertidumbre y su impacto en la supply chain textil.....	54
Tabla 5. Evidencia empírica del problema diagnosticado en los estudios revisados	56
Tabla 6. Resumen de estudios previos en forecasting textil y retail.....	58
Tabla 7. Estudios pertenecientes al sector textil.....	65
Tabla 8. Estudios de sectores comparables incluidos en la revisión	65
Tabla 9. Problemas relacionados con la precisión del forecast identificados en la literatura	69
Tabla 10. Problemas operativos asociados identificados en la literatura	70
Tabla 11. Problemas metodológicos identificados en la literatura	71
Tabla 12. Factores de complejidad del entorno identificados en la literatura	73
Tabla 13. Métodos empíricos más comunes identificados en la literatura.	75
Tabla 14. Modelos estadísticos más comunes usados en los estudios analizados	76
Tabla 15. Matriz maestra de extracción documental	99
Tabla 16. Matriz comparativa metodológica de los estudios analizados.....	104
Tabla 17. Glosario de términos	109

1. Introducción

1.1. Contexto general de la industria textil (regional y nacional)

La industria textil es uno de los sectores productivos más relevantes a nivel global, tanto por su impacto económico como por el empleo que genera. Según datos de la International Labour Organization (2022), los sectores de textiles y confección empleaban cerca de 90 millones de personas en 2019 y cuentan con estimaciones de más de 60 millones de trabajadores para el conjunto de textiles, confección, cuero y calzado. Según la Comisión Económica para América Latina y el Caribe (2023), en América Latina la industria textil ha experimentado un proceso de transformación en los últimos años; caracterizado por la apertura comercial, la competencia de importaciones asiáticas y la necesidad de modernizar procesos productivos para mantener competitividad. La política industrial sigue siendo tan relevante como en el pasado, y los avances hacia un desarrollo sostenible e inclusivo dependen de una gestión basada en información y en el uso de indicadores estadísticos confiables. En este sentido, la CEPAL enfatiza que la disponibilidad de datos desagregados por actividad económica permite diseñar políticas industriales más precisas, al posibilitar el análisis de aspectos clave como innovación, productividad, estructura empresarial y empleo sectorial. Este enfoque resulta especialmente útil para comprender la dinámica de sectores como el textil e indumentaria, donde la competitividad y la capacidad de adaptación dependen de políticas y decisiones basadas en evidencia.

Desde una perspectiva estructural, diversos estudios señalan que la industria textil presenta características productivas particulares que influyen directamente en su funcionamiento operativo. En muchos países y regiones, el sector está compuesto principalmente por pequeñas y medianas empresas, muchas de ellas de carácter familiar, lo que genera una estructura productiva atomizada y heterogénea (Altamirano & Caruso, 2015). Asimismo, se trata de una industria intensiva en mano de obra, especialmente en las etapas de confección y costura, actividades que representan una proporción significativa de la fuerza laboral del sector y que presentan limitaciones para su automatización debido a la naturaleza flexible de los materiales textiles (ILO, 2022).

Otra característica relevante de la industria es la fuerte influencia de la moda y la estacionalidad en los patrones de consumo. La demanda de productos textiles suele presentar picos asociados a temporadas específicas, como las colecciones primavera-verano y otoño-invierno, así como a eventos promocionales que estimulan el consumo. Esto implica que los ciclos de vida de los productos tienden a ser relativamente cortos, obligando a las empresas a adaptar constantemente su oferta para responder a cambios en las

preferencias de los consumidores. A ello se suma la gran diversidad de variantes que deben ofrecerse para un mismo producto, como tallas, colores o estilos, lo que incrementa significativamente la complejidad de la gestión de inventarios y de la planificación de la producción (Valera García, 2022).

En Argentina, la cadena textil-confección representa aproximadamente el 6 % del valor agregado industrial y se encuentra altamente expuesta a las fluctuaciones macroeconómicas, particularmente al tipo de cambio, la evolución del poder adquisitivo de los hogares, los niveles de consumo interno y la variabilidad de los costos de las materias primas (CAME, 2025). El poder adquisitivo constituye una variable clave para comprender el comportamiento de la demanda, ya que refleja la capacidad real de compra de los consumidores al integrar la evolución de sus ingresos con el nivel general de precios (Braun & Llach, 2010). En este sentido, la inflación no determina por sí sola las decisiones de consumo, sino que actúa como uno de los factores que puede erosionar el poder adquisitivo cuando el incremento de los precios supera el crecimiento de los ingresos reales (Gonzales Perez, 2020). La estructura productiva incluye desde hilanderías y tejedurías hasta confeccionistas y marcas de indumentaria, lo que la convierte en una industria compleja y con un alto grado de integración vertical. En este contexto, un planeamiento de la demanda preciso no solo permite coordinar eficientemente los distintos eslabones de la cadena de suministro, sino que también tiene impactos directos en la rentabilidad y sostenibilidad financiera de las empresas. Un forecast confiable reduce la acumulación de inventario innecesario, lo que disminuye la inmovilización de capital de trabajo y los costos de almacenamiento (Silver, Pyke, & Thomas, 2016). Asimismo, contribuye a mantener niveles adecuados de servicio al cliente, evitando quiebres de stock que afectan las ventas y la reputación de la marca. Hugos (2003) afirma que tener también una planificación adecuada de la producción y las compras ayuda a optimizar los flujos de caja, alinear las necesidades de financiamiento y reducir pérdidas por obsolescencia, especialmente en un sector tan sensible a las tendencias de moda y a la estacionalidad. En conjunto, el demand planning actúa como un mecanismo de integración que conecta decisiones estratégicas, tácticas y operativas, asegurando que los recursos se utilicen de manera eficiente y que la cadena de suministro responda con agilidad a los cambios del mercado.

1.2. Entorno cambiante: poder adquisitivo, consumo y estacionalidad

El contexto macroeconómico argentino se caracteriza por una elevada volatilidad económica que incide directamente sobre el poder adquisitivo de los hogares, entendido como la capacidad real de compra que resulta de la relación entre los ingresos y el nivel general de precios (Braun & Llach, 2010). La inflación, que alcanzó el 211,4 % interanual en 2023

(INDEC, 2024), constituye uno de los principales factores que afectan dicha capacidad de compra, especialmente cuando el incremento de los precios supera la evolución de los ingresos reales (Gonzales Perez, 2020). Como consecuencia, se producen modificaciones en los patrones de consumo, generando una mayor volatilidad en la demanda y obligando a las empresas a ajustar continuamente sus estrategias de producción y abastecimiento.

La incertidumbre macroeconómica también impacta directamente en la previsibilidad del comportamiento del consumidor, generando variaciones abruptas en los niveles de demanda y dificultando la planificación de la producción y la gestión de inventarios. Las decisiones de consumo responden principalmente a la evolución del ingreso real de los hogares y a sus expectativas económicas futuras, por lo que cambios en el poder adquisitivo modifican no solo el volumen de bienes demandados, sino también la composición del consumo, orientando las compras hacia productos considerados esenciales o de menor precio cuando la capacidad de compra disminuye (Gonzales, 2011). La coexistencia de cambios en el poder adquisitivo, elevada estacionalidad y rápidas variaciones en las preferencias de los consumidores incrementa la incertidumbre que enfrentan las empresas textiles, haciendo que la demanda resulte particularmente difícil de anticipar mediante enfoques tradicionales. En este contexto, las empresas deben tomar decisiones en horizontes de planificación cada vez más cortos, lo que incrementa la necesidad de contar con herramientas analíticas que permitan anticipar cambios en los patrones de consumo.

Además, la industria textil presenta una alta estacionalidad, con picos de demanda vinculados a lanzamientos de colecciones (primavera/verano y otoño/invierno) y eventos promocionales (Hot Sale, CyberMonday) que deben ser anticipados con precisión para evitar quiebres de stock o sobreproducción (Ivanov, Tsipoulidis, & Schonberger, 2021). La combinación entre estacionalidad, ciclos de vida cortos de los productos y cambios frecuentes en las tendencias de moda provoca que la demanda en este sector sea particularmente difícil de predecir. A su vez, la gran variedad de combinaciones de productos (como tallas, colores y modelos) incrementa la complejidad de la planificación, ya que cada variante debe gestionarse como una unidad de inventario distinta. En este entorno VUCA (volátil, incierto, complejo y ambiguo), la capacidad de anticipar cambios en el comportamiento del consumidor se vuelve crítica para la sostenibilidad del negocio (Mohd Aris, Sarah Omar, & Hashim, 2014). En este contexto, la incertidumbre en la cadena de suministro puede clasificarse en distintos tipos según su naturaleza y disponibilidad de información, lo que condiciona las herramientas de análisis y planificación utilizadas por las organizaciones.

Tabla 1. Tipos de incertidumbre en la cadena de suministro.

Tipo de incertidumbre	Descripción	Ejemplo en industria textil
Aleatoria (Random)	Variabilidad normal en demanda y supply	Cambios semanales en ventas
De riesgo (Hazard)	Eventos de alto impacto y baja frecuencia	Quiebres por importaciones
Profunda (Deep)	Escenarios sin información clara	Crisis macroeconómica
Determinística	Información conocida	Pedidos confirmados
Difusa (Fuzzy)	Información imprecisa	Tendencias de moda

Fuente: Elaboración propia adaptado de (Ivanov, Tsipoulidis, & Schonberger, 2021).

Como se resume en la Tabla 1, la incertidumbre en la cadena de suministro no es homogénea, sino que abarca desde variaciones aleatorias hasta escenarios de incertidumbre profunda. En economías inestables como la argentina, predominan los entornos con información incompleta o cambiante, lo que limita la efectividad de enfoques tradicionales de planificación y refuerza la necesidad de modelos más robustos y adaptativos.

1.3. Rol del demand planning y problemáticas actuales (planificación empírica, uso de Excel)

En entornos donde el poder adquisitivo de los consumidores presenta variaciones frecuentes como consecuencia de cambios macroeconómicos, las empresas enfrentan una mayor incertidumbre para anticipar el comportamiento de la demanda. Esta situación incrementa la necesidad de contar con procesos de planificación estructurados y herramientas analíticas que permitan responder con mayor rapidez a las variaciones del mercado. El demand planning es un proceso clave dentro de la cadena de suministro, ya que busca generar un plan consensuado que alinee las áreas comerciales, de producción y logística alrededor de una proyección única de demanda (APICS, 2021). Una planificación de la demanda precisa reduce costos de inventario, mejora el nivel de servicio al cliente y permite una mejor utilización de la capacidad instalada (Silver, Pyke, & Thomas, 2016). En este sentido, el pronóstico de demanda se convierte en uno de los pilares fundamentales para la coordinación

de las actividades operativas, ya que permite anticipar las necesidades del mercado y ajustar de manera oportuna los planes de producción, abastecimiento y distribución.

Sin embargo, en muchas empresas textiles de Argentina, el pronóstico se sigue realizando de forma manual y empírica, apoyado en hojas de cálculo y en el juicio de expertos. Esto dificulta la detección de patrones de consumo, introduce sesgos en las proyecciones y aumenta el riesgo de decisiones reactivas en lugar de estratégicas. Este enfoque, basado principalmente en la experiencia de los planificadores, suele carecer de herramientas analíticas que permitan identificar de manera sistemática tendencias, ciclos o variaciones estacionales en la demanda, lo que limita la capacidad de las organizaciones para anticipar cambios en el mercado.

La ausencia de métodos estadísticos formalmente aplicados limita significativamente la capacidad de capturar estacionalidades y tendencias de largo plazo, lo que provoca que los planes de producción y compras no reflejan de manera precisa la demanda futura. Además, sin modelos que incorporen componentes de suavización o de ajuste por variabilidad, las empresas tienden a sobreestimar o subestimar la demanda, generando quiebres de stock, sobre-inventarios y mayores costos de almacenamiento (Petropoulos, Hyndman, Bergmeir, & Talagala, 2022). El uso de técnicas estadísticas (como Holt-Winters, ARIMA o modelos causales) permite descomponer la serie de tiempo en sus componentes principales (nivel, tendencia, estacionalidad, error); lo que ofrece una visión más granular y confiable del comportamiento de la demanda según lo dicho por Hyndman & Athanasopoulos (2021). Vandepu (2023) comenta que, de esta manera, las organizaciones pueden reaccionar con mayor agilidad ante cambios del mercado, ajustar su mix de productos y optimizar la asignación de recursos generando beneficios tanto operativos como financieros.

Asimismo, la incorporación de modelos cuantitativos permite reducir la dependencia exclusiva del juicio humano en la elaboración de pronósticos, favoreciendo la toma de decisiones basada en datos y mejorando la consistencia de los planes de demanda en entornos de alta incertidumbre.

1.4. Planteamiento del problema y justificación del estudio

Actualmente, diversos estudios aplicados evidencian que los procesos de pronóstico de demanda continúan caracterizándose por un bajo nivel de formalización, reflejado en la dependencia del juicio experto, la escasez de datos históricos, la utilización de hojas de cálculo, la falta de integración de la información y la presencia de procesos manuales para apoyar la planificación. Estas limitaciones han sido documentadas en investigaciones desarrolladas en Argentina, Colombia, Perú y otros contextos comparables, donde se identifican problemas asociados a la centralización de decisiones, la planificación reactiva y

las dificultades para gestionar y analizar la información de manera oportuna (Altamirano & Caruso, 2015; Arrieta et al., 2017; Huaca León, 2018; Valera García, 2022). Como consecuencia, estas prácticas repercuten directamente en la planificación de la producción, la gestión de inventarios y el desempeño de la cadena de suministro.

En sectores caracterizados por alta volatilidad y ciclos de vida de producto cortos, como la industria textil, la calidad del pronóstico de demanda se convierte en un factor crítico para coordinar la producción, las compras y la gestión de inventarios. Cuando los pronósticos se elaboran sin herramientas analíticas adecuadas o mediante procesos poco estructurados, aumenta la probabilidad de generar desajustes entre la oferta y la demanda real del mercado (Makridakis, Wheelwright, & Hyndman, 1998).

Entre las principales consecuencias de este enfoque se encuentran:

- Distorsión de la información entre periodos y dificultad para rastrear de forma ágil la evolución de artículos, ventas y demanda, generando desajustes en la planificación y reduciendo la confiabilidad de los datos.
- Falta de información oportuna e integrada, ya que muchas empresas carecen de sistemas interconectados; las consultas deben realizarse por separado y luego consolidarse manualmente, aumentando el riesgo de errores humanos.
- Reportes deficientes y propensos a inconsistencias, debido a que la consolidación y el análisis se realizan de forma manual, dificultando la detección de patrones, tendencias, estacionalidades o anomalías.
- Dependencia de metodologías empíricas, basadas más en intuición que en modelos cuantitativos, lo que se traduce en pronósticos con baja exactitud que no consideran adecuadamente la volatilidad, incertidumbre, complejidad y ambigüedad (entorno VUCA) del sector textil.

Esta brecha entre métodos empíricos y modelos estadísticos robustos representa un desafío crítico para el sector, ya que impacta la disponibilidad de productos, la inmovilización de inventario y, en última instancia, la rentabilidad de las empresas (Hugos, 2003). Además, la creciente complejidad de los mercados, la aceleración de las tendencias de consumo y la necesidad de responder con rapidez a los cambios en la demanda hacen que los enfoques tradicionales basados exclusivamente en experiencia o intuición resulten cada vez menos adecuados para apoyar la toma de decisiones estratégicas.

Frente a esta situación, resulta necesario analizar la evidencia disponible sobre la aplicación de métodos estadísticos en el pronóstico de demanda, identificando en qué medida han demostrado mejorar la precisión y confiabilidad de las proyecciones en contextos

comparables. En este sentido, la revisión de la literatura académica y de estudios aplicados permite evaluar cómo diferentes metodologías de forecasting han contribuido a mejorar la precisión del pronóstico en sectores con características similares, proporcionando una base analítica para comprender el impacto potencial de estas herramientas en la planificación de la demanda en la industria textil.

1.5. Objetivo general, hipótesis y objetivos específicos

En base a la problemática expuesta, el objetivo general de este trabajo se centra en analizar, a partir de la literatura académica y estudios de caso, la eficiencia de distintos métodos estadísticos de pronóstico de demanda en contextos de alta complejidad y variabilidad característicos de la industria textil. El propósito es evaluar su impacto en la reducción del error de forecast en comparación con metodologías empíricas tradicionales, contribuyendo a mejorar la toma de decisiones en planificación de producción, compras e inventarios.

La hipótesis de este trabajo sostiene que la adopción de métodos estadísticos de pronóstico (suavización exponencial, modelos ARIMA/SARIMA y técnicas de machine learning) reduce el error de forecast (MAPE, WAPE) en comparación con los métodos empíricos tradicionales, incrementando la confiabilidad de la información utilizada en la planificación de la cadena de suministro. Cabe aclarar que, dado que el diseño de esta investigación es de tipo documental y comparativo, la verificación de esta hipótesis no se realiza mediante una prueba estadística sobre datos propios, sino a través del contraste cualitativo y sistemático de la evidencia reportada en la literatura académica revisada (ver Tabla 15, Anexo 2). En este sentido, la hipótesis se entiende como una proposición orientadora que guía el análisis comparativo entre métodos estadísticos y empíricos, y se considera sustentada en la medida en que la evidencia documental revisada muestre, de manera coherente y consistente, mejoras de precisión asociadas a la aplicación de métodos estadísticos.

Finalmente, y desprendiéndose del objetivo general, se plantean los siguientes objetivos específicos:

- Identificar y describir, a partir de la literatura y estudios previos, las variables críticas que influyen en el pronóstico de demanda en el sector textil y en industrias comparables, así como su relevancia para mejorar la precisión de los modelos estadísticos.
- Analizar los supuestos y escenarios de simulación propuestos en investigaciones que aborden entornos VUCA, con el fin de comprender cómo afectan la robustez y aplicabilidad de los pronósticos de demanda.

- Revisar y sistematizar estudios académicos y casos de aplicación que utilice modelos estadísticos de pronóstico de demanda en la industria textil o sectores comparables, identificando variables, parámetros y segmentaciones utilizadas en cada enfoque.
- Comparar los resultados reportados en la literatura entre metodologías empíricas y modelos estadísticos, analizando los errores de predicción (MAPE, WAPE) y evaluando en qué medida los métodos cuantitativos han demostrado mejoras en precisión y confiabilidad del forecast.

1.6. Alcance y limitaciones

En cuanto al alcance de este estudio, el análisis se concentra en la precisión del pronóstico de demanda dentro de la industria textil argentina, un sector caracterizado por alta estacionalidad, inflación persistente y cambios frecuentes en los patrones de consumo. El enfoque está puesto en la demanda expresada en unidades físicas, con el objetivo de aislar el efecto de los métodos estadísticos de factores propios de la cadena de suministro; como restricciones de capacidad, quiebres de stock, problemas de aprovisionamiento o demoras logísticas que podrían distorsionar la interpretación de la demanda real. De esta manera, el estudio busca analizar exclusivamente la relación entre la metodología de pronóstico y la calidad de la información que nutre los planes de compras y producción, dejando fuera del alcance los procesos operativos de programación, logística o inventarios. Finalmente, aunque el análisis se sitúa en el contexto argentino, sus conclusiones se presentan de manera que puedan servir de referencia para otras industrias textiles que operan en entornos de similar complejidad.

Respecto a las limitaciones, es importante reconocer que se trata de un estudio de carácter teórico y de revisión bibliográfica, por lo que no incluye recolección de datos primarios ni validación empírica directa en una empresa específica. Si bien se priorizan investigaciones aplicadas a la industria textil, algunos hallazgos provienen de sectores comparables, como retail o bienes de consumo masivo, lo que podría introducir sesgos al extrapolar resultados al mercado argentino. Además, el uso de series históricas y supuestos de simulación reportados en la literatura no necesariamente refleja de manera exacta la volatilidad económica actual, por lo que los hallazgos deben interpretarse como una aproximación académica y no como un forecast operativo listo para implementación. Finalmente, el análisis excluye indicadores financieros (ingresos, márgenes o rentabilidad) y variables operativas de supply chain (capacidad de planta, costos de producción, lead times), lo que, si bien permite aislar el efecto de los métodos estadísticos sobre la precisión del pronóstico, limita la cuantificación del impacto económico integral de las mejoras. No obstante, este enfoque acotado permite

generar conclusiones robustas que sirvan de base para futuras investigaciones empíricas o desarrollos de modelos de simulación aplicados en casos reales.

2. Marco Teórico

2.1. Fundamentos del pronóstico de demanda

2.1.1. Definiciones básicas

- **Forecast (pronóstico):** El *forecast* es la estimación del comportamiento futuro de una variable (como la demanda o las ventas) basada en información histórica y en el análisis de factores que pueden afectar su evolución. En la gestión de la demanda, constituye la base para planificar producción, inventarios y abastecimiento, permitiendo reducir la incertidumbre y mejorar la coordinación entre áreas (Hyndman & Athanasopoulos, 2021). Los pronósticos pueden clasificarse según su horizonte temporal (corto, mediano o largo plazo), su nivel de agregación (estratégico, táctico u operativo) y la naturaleza del método (cualitativo o cuantitativo), dependiendo de la información disponible y del tipo de decisión que se busca respaldar.

En términos de gestión de operaciones, el pronóstico constituye el insumo principal para los sistemas de planificación empresarial, ya que permite estimar la demanda futura a partir de datos históricos, juicio experto o una combinación de ambos enfoques (Mora Garcia, 2010). Esta capacidad de anticipación permite que las organizaciones pasen de una lógica reactiva a una planificación proactiva de sus recursos productivos y logísticos (Nahmias, 2015).

La literatura también señala que el forecasting posee una doble naturaleza: por un lado, se apoya en métodos cuantitativos y modelos estadísticos, y por otro requiere la interpretación de información contextual del mercado. Por ello suele describirse como una actividad que combina elementos de ciencia y arte dentro de la gestión de operaciones (Huaca León, 2018).

- **Demanda:** La demanda representa la cantidad de bienes o servicios que los consumidores desean y pueden adquirir en un periodo específico. Se diferencia de las ventas, ya que refleja la intención de compra más allá de las limitaciones de oferta. Comprender la demanda es clave para ajustar los planes de producción y distribución, y en sectores como el textil, su variabilidad se ve influida por factores estacionales, económicos y de tendencia (Hyndman & Athanasopoulos, 2021).

Desde una perspectiva operativa, la demanda puede definirse también como la necesidad de un producto o componente particular manifestada a través de órdenes de clientes, requerimientos entre plantas o estimaciones de pronóstico (Mora Garcia,


2010). En este sentido, la demanda constituye el punto de partida de los procesos de planificación empresarial, ya que determina los niveles de producción, abastecimiento e inventario requeridos para satisfacer al mercado (Valera García, 2022).

Es importante distinguir entre demanda y ventas. Mientras que las ventas reflejan únicamente las transacciones efectivamente realizadas, la demanda representa el requerimiento real del mercado. En situaciones de quiebre de stock o restricciones de oferta, las ventas pueden subestimar la demanda real al no considerar las denominadas ventas perdidas, lo que puede generar distorsiones en los modelos de pronóstico si no se realizan los ajustes correspondientes (Nahmias, 2015).

Asimismo, la literatura distingue entre demanda independiente (generada directamente por el consumidor final) y demanda dependiente, que surge como consecuencia de los requerimientos de producción de otros productos dentro del sistema (Ramírez Agudelo, 2013).

- **Poder adquisitivo:** El poder adquisitivo representa la capacidad real de compra de los consumidores y resulta de la relación entre los ingresos disponibles y el nivel general de precios de la economía. A diferencia de la inflación, que únicamente mide la variación de los precios, el poder adquisitivo refleja cuánto pueden adquirir efectivamente los hogares con sus ingresos, convirtiéndose en un indicador más representativo del comportamiento del consumo. Cuando el incremento de los precios supera el crecimiento de los ingresos reales, el poder adquisitivo disminuye, afectando las decisiones de compra y modificando tanto el volumen como la composición de la demanda (Braun & Llach, 2010). En consecuencia, el poder adquisitivo constituye una variable macroeconómica de especial interés para el pronóstico de demanda, ya que condiciona el comportamiento del consumo y, por ende, la cantidad de bienes que las empresas deberán producir, abastecer y comercializar (Gonzales Perez, 2020).

Figura 1. Evolución del salario real promedio en Argentina (índice 1960=100) y tendencia utilizando el filtro Hodrick-Prescott, 1950-2006.



Fuente: (Gonzales, 2011)

La Figura 1 evidencia que la evolución del salario real, como aproximación a la evolución del poder adquisitivo de los hogares, ha presentado importantes fluctuaciones a lo largo de las últimas décadas. Si bien la economía argentina atravesó distintos períodos de crecimiento, la capacidad de compra de los trabajadores no mostró una mejora sostenida, alcanzando en 2006 niveles similares a los registrados en 1960. Esto demuestra que el crecimiento económico no necesariamente se traduce en un mayor poder adquisitivo, siendo este último el factor que condiciona de manera más directa el comportamiento del consumo y, en consecuencia, la demanda que las empresas deben pronosticar.

- **Error de previsión:** El error de previsión es la diferencia entre la demanda real y el valor pronosticado. Su medición permite evaluar la efectividad del modelo y ajustar procesos de planificación. Las métricas más comunes son el MAPE, WAPE y RMSE, que permiten analizar precisión, sesgo y magnitud del error (Hyndman & Athanasopoulos, 2021). Un monitoreo constante del error es esencial para mejorar la confiabilidad del proceso de forecast.

Debido a la naturaleza incierta y variable de la demanda, el error de pronóstico es inevitable en cualquier modelo predictivo. Por esta razón, el análisis del error constituye una herramienta fundamental para evaluar el desempeño de los modelos

de forecasting y seleccionar la metodología que mejor se ajusta al comportamiento del mercado (Altamirano & Caruso, 2015).

En la práctica, el error de pronóstico se relaciona directamente con la gestión de inventarios, ya que una mayor variabilidad en los errores implica mayor incertidumbre en la demanda futura y, por lo tanto, mayores niveles de inventario de seguridad para garantizar el nivel de servicio al cliente (Nahmias, 2015).

- **Horizonte, nivel y unidad de pronóstico:** El horizonte de pronóstico define el período futuro estimado; puede ser corto (semanal o mensual), mediano (trimestral) o largo plazo (anual). Un horizonte corto plazo se utiliza para decisiones operativas, como programación de producción, gestión de inventarios o reposición de materiales. Un horizonte mediano apoya decisiones tácticas, como la planificación de capacidad, compras o contratación de personal; y, finalmente, el largo plazo (anual o superior) se emplea para decisiones estratégicas, como inversiones, desarrollo de nuevos productos o expansión de mercados (Makridakis, Wheelwright, & Hyndman, 1998).

Tabla 2. Relación entre horizonte de pronóstico y toma de decisiones

Horizonte	Periodo	Tipo de decisión	Aplicación en supply chain	Aplicación en industria textil argentina
Corto plazo	Horas / días	Operativa	Reposición, inventarios, programación	Reposición rápida de prendas, ajuste de stock en tiendas
Mediano plazo	Semanas / meses	Táctica	Planificación de demanda, distribución, workforce	Planificación de colecciones, campañas comerciales, compras de temporada
Largo plazo	1 año o más	Estratégica	Capacidad, inversiones, red logística	Definición de surtido, expansión de canales, estrategia de producción

. Fuente: *Elaboración propia adaptado de (Nahmias, 2015).*

Como se observa en la Tabla 2, el horizonte de pronóstico se encuentra directamente vinculado con el tipo de decisiones organizacionales, diferenciándose en niveles operativos, tácticos y estratégicos. Asimismo, se evidencia cómo cada horizonte temporal impacta de manera específica en la gestión de la cadena de suministro y, particularmente, en la industria textil argentina, donde la planificación de colecciones,

la reposición de inventarios y la definición de estrategias comerciales requieren distintos niveles de anticipación.

El nivel de pronóstico define el grado de agregación del análisis: puede realizarse a nivel empresa, categoría, canal o SKU, dependiendo del alcance del proceso de planificación. La unidad de pronóstico, por otro lado, especifica la variable medida, como unidades físicas o toneladas y debe ser consistente con los indicadores de desempeño utilizados por la organización.

Una definición coherente de estos tres elementos permite integrar los distintos plazos de planificación y asegurar que las áreas operativas, tácticas y estratégicas trabajen bajo una misma visión de la demanda (Silver, Pyke, & Thomas, 2016).

El horizonte de pronóstico determina también el tipo de decisiones que puede soportar el forecast. Horizontes de corto plazo se asocian principalmente a decisiones operativas, como la programación de turnos o la reposición de inventarios, mientras que horizontes más amplios permiten planificar la capacidad productiva, la fuerza laboral o incluso inversiones estratégicas en infraestructura (Nahmias, 2015).

- **Sesgo del forecast (bias):** El sesgo del pronóstico refleja la tendencia sistemática de un modelo a sobrestimar o subestimar la demanda real. A diferencia de los errores aleatorios, el sesgo no se cancela en el tiempo, por lo que puede generar desviaciones persistentes que afectan la planificación. Un sesgo positivo (sobreestimación) conduce a exceso de inventario, mayores costos de almacenamiento y menor rotación, mientras que un sesgo negativo (subestimación) puede ocasionar quiebres de stock, retrasos en la entrega y pérdida de ventas. Por lo tanto, detectar y corregir el sesgo se vuelve clave para mantener la confiabilidad del proceso de planificación. Esto se logra mediante la revisión continua de los pronósticos, la comparación con la demanda real y el uso de métricas como el *Forecast Bias* o el *Mean Percentage Error* (MPE). Un forecast sin control de sesgo puede transmitir señales erróneas al proceso de S&OP, afectando tanto la eficiencia operativa como la percepción de desempeño del área de demanda (Nahmias, 2015).

El análisis del sesgo permite identificar desviaciones sistemáticas en los modelos de pronóstico y corregir posibles influencias subjetivas inapropiadas dentro del proceso de planificación. Su monitoreo continuo resulta fundamental para mantener la confiabilidad del forecast y asegurar una adecuada alineación entre las proyecciones de demanda y las decisiones operativas de la cadena de suministro (Silver, Pyke, & Thomas, 2016).

- **Exactitud y precisión:** La exactitud (accuracy) y la precisión (precision) son dos conceptos fundamentales para evaluar la calidad de un pronóstico. La exactitud mide qué tan cerca está el valor pronosticado del valor real, mientras que la precisión evalúa

la consistencia de los errores a lo largo del tiempo . En otras palabras, un modelo puede ser muy preciso (es decir, cometer errores similares de manera repetida), pero inexacto si mantiene un sesgo constante. En el contexto de la planificación de la demanda, lograr alta exactitud implica minimizar el error medio (por ejemplo, el MAPE o el WAPE), mientras que alcanzar buena precisión asegura estabilidad en los resultados y confianza en las decisiones. Cuando ambos aspectos se equilibran, el forecast se convierte en una herramienta confiable para coordinar áreas como compras, producción y logística, reduciendo costos y mejorando la respuesta al mercado (Makridakis, Wheelwright, & Hyndman, 1998).

En el contexto del proceso de Sales and Operations Planning (S&OP), la exactitud y la precisión del pronóstico constituyen indicadores clave para evaluar la confiabilidad del proceso de planificación, ya que influyen directamente en la capacidad de la organización para equilibrar la demanda del mercado con las capacidades operativas de la empresa (Silver, Pyke, & Thomas, 2016).

- **Métodos cualitativos y cuantitativos:** Los métodos cualitativos se basan en el juicio experto y son especialmente útiles cuando hay pocos datos históricos o cambios estructurales (p. ej., lanzamientos o shocks), mientras que los métodos cuantitativos utilizan datos históricos y modelos estadísticos para producir pronósticos replicables (Petroopoulos, Hyndman, Bergmeir, & Talagala, 2022). Entre los métodos más utilizados destacan el *Delphi*, los paneles de expertos y el consenso de ventas, que aportan información valiosa en contextos de alta incertidumbre. Por otro lado, los métodos cuantitativos se sustentan en el análisis de datos históricos y en la identificación de patrones estadísticos. Incluyen modelos de series de tiempo (como promedio móvil, suavizamiento exponencial o ARIMA) y modelos causales, que incorporan variables explicativas como precio, promociones o factores macroeconómicos (Hyndman & Athanasopoulos, 2021). En los últimos años, estos métodos se han complementado con algoritmos de aprendizaje automático, que permiten capturar relaciones más complejas y mejorar la precisión del pronóstico. En la práctica, muchas organizaciones combinan ambos enfoques dentro de sus procesos de planificación de la demanda. Mientras los métodos cuantitativos proporcionan consistencia y rigor analítico, el juicio experto permite incorporar información contextual del mercado que no siempre se refleja en los datos históricos, como cambios en tendencias de consumo, decisiones comerciales o eventos extraordinarios.

2.1.2. Diferencia entre demanda real y ventas (restricciones de supply)

La demanda real representa la cantidad de producto que los clientes desean adquirir en un período determinado, mientras que las ventas efectivas reflejan únicamente lo que la empresa logra entregar o facturar. Esta diferencia es clave, ya que la demanda puede verse insatisfecha por limitaciones de capacidad productiva, falta de inventario, problemas logísticos o rupturas en la cadena de suministro (Nahmias, 2015). En la práctica, muchas organizaciones basan sus pronósticos en las ventas históricas, lo que puede generar subestimaciones sistemáticas de la demanda cuando existen restricciones de oferta. Esto ocurre, por ejemplo, cuando un producto se agota en tienda: las ventas se detienen, pero la demanda continúa latente. Si el modelo no corrige esta distorsión, el forecast refleja niveles menores a la demanda real, afectando la planificación futura. Reconocer esta diferencia permite ajustar las proyecciones y estimar la demanda no atendida, mejorando la precisión del proceso de planificación. En industrias como la textil, donde los ciclos de vida son cortos y las variaciones de demanda son altas, considerar las restricciones de *supply* resulta esencial para evitar quiebres de stock o exceso de producción.

Desde la perspectiva de la gestión de la cadena de suministro, la distinción entre demanda y ventas no es únicamente conceptual, sino que constituye un elemento central para evitar distorsiones en los procesos de planificación operativa. Mientras las ventas representan transacciones registradas en el sistema, la demanda refleja el requerimiento total del mercado, independientemente de si la empresa tuvo la capacidad de satisfacerlo o no (Nahmias, 2015).

En condiciones ideales de abastecimiento ilimitado, las ventas y la demanda coincidirían. Sin embargo, en los entornos reales de operación existen diversas restricciones de oferta que generan una brecha entre ambas variables. Entre las más comunes se encuentran los quiebres de stock, las limitaciones de capacidad productiva, los cuellos de botella en el sistema de producción, los problemas logísticos en la distribución o incluso restricciones financieras que limitan la capacidad de reposición de inventarios (Hyndman & Athanasopoulos, 2021).

Los quiebres de stock constituyen uno de los casos más evidentes de esta diferencia. Cuando el inventario disponible se agota, cualquier intención de compra adicional por parte del cliente no se registra como venta en el sistema. Como resultado, los datos históricos reflejan únicamente las unidades vendidas, pero no capturan la magnitud total de la demanda potencial del mercado (Nahmias, 2015).

Este fenómeno da lugar al concepto de ventas perdidas o lost sales, que ocurre cuando los consumidores no pueden adquirir el producto debido a la falta de disponibilidad y optan por buscar alternativas en otros establecimientos. Desde el punto de vista estadístico, esta situación se conoce como demanda censurada, ya que los registros históricos contienen información incompleta sobre el comportamiento real del mercado: se observa cuánto se vendió, pero no cuánto se habría vendido si el producto hubiera estado disponible (Nahmias, 2015).




Figura. 1 . Seguimiento de la media tomando en cuenta valores censurados (ventas) y no censurados (corrigiendo ventas perdidas). Fuente: (Nahmias, 2015).




Figura. 2. Seguimiento de la desviación estándar en presencia de ventas perdidas. Fuente: (Nahmias, 2015).

Como se observa en las Figuras 1 y 2, el uso de datos censurados genera distorsiones en la estimación tanto del nivel promedio como de la variabilidad de la demanda, evidenciando diferencias entre los valores reales y aquellos obtenidos a partir de ventas observadas.

Cabe destacar que el valor promedio representado no corresponde directamente a una decisión de producción, sino a una referencia estadística de la demanda esperada. En la práctica, las decisiones operativas incorporan ajustes adicionales, como el stock de seguridad, por lo que el impacto del error de estimación no se traduce de forma directa en quiebres o sobrestock, sino en desviaciones en la planificación.

El uso exclusivo de datos de ventas históricas para alimentar modelos de pronóstico puede generar errores sistemáticos importantes. En primer lugar, se produce una subestimación de la demanda promedio, ya que los picos de demanda no satisfechos no quedan registrados en la base de datos. En segundo lugar, se introduce un sesgo hacia abajo en los modelos de forecasting, los cuales interpretan los periodos de quiebre de stock como señales de menor demanda en lugar de reconocer la restricción de oferta que los originó. Finalmente, las ventas observadas tienden a mostrar una variabilidad menor que la demanda real, lo que conduce a una subestimación de la varianza y, en consecuencia, a cálculos incorrectos del inventario de seguridad necesario para garantizar el nivel de servicio (Altamirano & Caruso, 2015).

Las implicancias de esta distorsión se reflejan directamente en la planificación de la cadena de suministro. Pronósticos basados en ventas censuradas pueden derivar en niveles de

inventario insuficientes, programas de producción que no cubren las necesidades reales del mercado y mayores probabilidades de quiebres de stock recurrentes. Además, la falta de visibilidad sobre la demanda real puede amplificar el efecto látigo en la cadena de suministro, ya que las órdenes transmitidas entre los distintos eslabones no reflejan con precisión el consumo final del mercado (Altamirano & Caruso, 2015).

Cabe señalar que, además de la problemática asociada al uso de ventas censuradas, en ciertos contextos industriales la demanda puede no materializarse en el mismo período en el que se genera, sino registrarse mediante pedidos con fechas de entrega diferidas. Este fenómeno, que puede denominarse demanda diferida, implica una separación temporal entre la generación de la demanda y su conversión en ventas, lo que introduce una complejidad adicional en el proceso de forecasting. A diferencia de la situación de ventas censuradas (donde la venta no ocurre por restricciones de oferta), en la demanda diferida la venta sí se concreta, pero en un período distinto al de la solicitud inicial, lo que puede distorsionar la lectura de los datos históricos si no se consideran adecuadamente los tiempos de entrega. En este sentido, la correcta interpretación de la demanda requiere distinguir entre ventas observadas, ventas censuradas (sujetas a stock disponible) y demanda comprometida a futuro (diferida), a fin de mejorar la precisión de los modelos de pronóstico y su alineación con la planificación operativa.

En industrias como la textil y el retail, caracterizadas por ciclos de vida cortos de los productos y una alta volatilidad de la demanda, esta problemática se vuelve particularmente crítica. Un producto de moda puede agotarse rápidamente debido a una tendencia inesperada; si la empresa utiliza únicamente las ventas registradas para planificar temporadas futuras, es probable que subestime el verdadero potencial del producto y repita los quiebres de stock en ciclos posteriores. Por esta razón, muchas organizaciones implementan mecanismos de monitoreo de inventario y análisis de ventas perdidas para estimar la demanda real del mercado y mejorar la precisión de sus procesos de forecasting (Hyndman & Athanasopoulos, 2021).

2.1.3. Relevancia del forecasting en cadenas de suministro textiles

El pronóstico de la demanda cumple un papel estratégico en la industria textil, donde los productos presentan alta estacionalidad, ciclos de vida cortos y una fuerte influencia de las tendencias de moda. Estas características hacen que el forecast no solo sea una herramienta de planificación, sino un factor crítico para la competitividad y la sostenibilidad del negocio (Hyndman & Athanasopoulos, 2021).

En este sector, el pronóstico de la demanda se convierte en un elemento central para la gestión de la cadena de suministro, ya que la volatilidad del mercado y la intensa competencia obligan a las empresas a tomar decisiones rápidas y coordinadas respecto a producción, inventarios y distribución. En este contexto, el forecasting no solo cumple una función predictiva, sino que actúa como un mecanismo de coordinación que permite alinear las decisiones operativas con las expectativas del mercado (Altamirano & Caruso, 2015).

Por lo tanto, como se muestra en la Figura. 3, el pronóstico de la demanda actúa como un elemento integrador que coordina las decisiones a lo largo de las distintas etapas de la cadena de suministro, desde el abastecimiento hasta la distribución final.




Figura. 3 . Rol del Forecasting en la cadena de suministro. Fuente: Elaboración Propia adaptado de (Nahmias, 2015)..

Una proyección bien calibrada permite coordinar decisiones de aprovisionamiento, producción y distribución, reduciendo costos por exceso de inventario y evitando quiebres de stock. Según estudios recientes sobre la industria textil, el uso de métodos estadísticos y modelos de aprendizaje automático contribuye a mejorar la consistencia y exactitud del pronóstico, aunque su efectividad depende de la calidad de los datos y del seguimiento continuo del error.

La complejidad del forecasting en este sector se explica por la combinación de factores estructurales que caracterizan a la industria de la indumentaria. En primer lugar, muchos productos poseen ciclos de vida extremadamente cortos, generalmente limitados a una

temporada de moda, lo que reduce la disponibilidad de datos históricos comparables para generar pronósticos confiables (Silver, Pyke, & Thomas, 2016). En segundo lugar, la demanda suele presentar una alta estacionalidad influenciada por el clima, el calendario comercial y eventos específicos de consumo, lo que obliga a considerar variables externas en los modelos de pronóstico (Kacmary, 2023).

Además, la rápida difusión de tendencias a través de redes sociales y medios digitales incrementa la variabilidad de la demanda, acelerando la rotación de estilos, colores y talles. Como consecuencia, los métodos estadísticos tradicionales suelen complementarse con el juicio experto o con información proveniente del mercado para capturar cambios cualitativos en las preferencias del consumidor (Altamirano & Caruso, 2015).

Además de las variables propias de la industria textil, el comportamiento de la demanda se encuentra condicionado por factores macroeconómicos que modifican la capacidad de compra de los consumidores. Entre ellos, el poder adquisitivo constituye una de las variables más relevantes para el proceso de forecasting, ya que determina el volumen potencial de consumo sobre el cual las empresas planifican su producción, abastecimiento e inventarios. Cuando el poder adquisitivo disminuye, los consumidores tienden a reducir o postergar compras de bienes no esenciales, modificando tanto el nivel como la composición de la demanda. Por ello, incorporar esta variable dentro del análisis del entorno permite construir pronósticos más representativos de la realidad del mercado.

En mercados como el argentino, la Confederación Argentina de la Mediana Empresa (2025) advierte que la fluctuación del consumo y los cambios macroeconómicos incrementan la necesidad de pronósticos más robustos, capaces de ajustarse ante entornos inestables. En su informe más reciente sobre el sector textil e indumentaria, la entidad señala una caída interanual real del 3,3% en las ventas, reflejo de una tendencia contractiva sostenida, apenas atenuada por fechas especiales como el Día de la Madre. Si bien las promociones y descuentos lograron reactivar parcialmente el movimiento comercial, el dinamismo se sostuvo a costa de los márgenes, con ventas orientadas al descuento, liquidación de stock y productos de menor valor, lo que confirma la fragilidad del consumo y la presión sobre la rentabilidad del rubro.

En este contexto, los errores de pronóstico pueden traducirse directamente en importantes ineficiencias económicas. Un pronóstico excesivamente optimista genera riesgos de sobrestock, es decir, acumulación de inventario que posteriormente debe liquidarse mediante descuentos agresivos, afectando la rentabilidad de la empresa (Nahmias, 2015). Por el contrario, una subestimación de la demanda produce quiebres de stock, ventas perdidas y

pérdida de clientes frente a competidores con mayor disponibilidad de producto (Valera García, 2022).

Desde una perspectiva de gestión de inventarios, estas decisiones pueden analizarse como un problema de equilibrio entre costos contrapuestos. En entornos de incertidumbre, las empresas deben definir cuánto producir o abastecer sin conocer con certeza la demanda futura, enfrentando simultáneamente el riesgo de excedentes y el de faltantes. Este trade-off constituye uno de los problemas clásicos en la teoría de inventarios estocásticos. Como se ilustra en la Figura. 4, la determinación de la cantidad óptima a producir o abastecer implica un equilibrio entre los costos de sobrestock y quiebre de stock. El modelo del “repartidor de periódicos” (newsvendor) muestra que existe un punto óptimo (Q^*) que minimiza el costo esperado total, considerando tanto el riesgo de excedentes como el de faltantes. Este enfoque resulta especialmente relevante en la industria textil, donde los productos poseen ciclos de vida cortos y las decisiones de abastecimiento deben tomarse con alta incertidumbre.




Figura. 4. Función de costo esperado y cantidad óptima en el modelo newsvendor. Fuente: (Nahmias, 2015).

En la Figura. 4, el eje horizontal (Q) representa la cantidad a producir o abastecer, mientras que el eje vertical ($G(Q)$) indica el costo esperado total asociado a dicha decisión. La forma convexa de la curva refleja que tanto niveles bajos como altos de producción generan costos elevados: en el primer caso, debido a quiebres de stock y ventas perdidas, y en el segundo, por sobrestock y liquidaciones. En este modelo, el costo de sobrestock (*overage cost*) se asocia a la pérdida por unidades no vendidas (como liquidaciones o costos de almacenamiento), mientras que el costo de quiebre de stock (*underage cost*) refleja el margen

perdido por no satisfacer la demanda. El punto mínimo de la curva (Q^*) corresponde a la cantidad óptima que equilibra ambos riesgos, minimizando el costo total esperado. En este sentido, cualquier desviación respecto a dicho punto incrementa el costo total esperado, lo que resalta la importancia de contar con pronósticos lo más precisos posibles.

Además, el forecasting aporta visibilidad a toda la cadena de valor: alinea áreas comerciales, de planificación y de operaciones bajo una misma proyección, favoreciendo un enfoque colaborativo dentro del proceso S&OP. Esto permite optimizar la asignación de recursos, anticipar oportunidades de mercado y responder con mayor agilidad a los cambios del entorno (Ivanov, Tsipoulандis, & Schonberger, 2021). En este sentido, resulta relevante comprender cómo el pronóstico de la demanda se integra dentro de la estructura general de la cadena de suministro. Para ello, existen modelos de referencia que permiten visualizar la interrelación entre los distintos procesos operativos y de planificación. Uno de los más utilizados es el modelo SCOR (Supply Chain Operations Reference), el cual proporciona un marco estandarizado para describir, analizar y mejorar el desempeño de la cadena de suministro (Figura. 5).



Figura. 5. Modelo SCOR de la cadena de suministro. Fuente: Elaboración propia adaptado de (Ivanov, Tsipoulандis, & Schonberger, 2021).

Como se observa, el modelo SCOR organiza la cadena de suministro en cinco procesos principales: planificación (Planificar), abastecimiento (Abastecer), producción (Producir), distribución (Distribuir) y devoluciones (Devoluciones).

distribución (Distribuir) y devoluciones (Return). Estos procesos abarcan de manera integral el flujo de materiales, información y decisiones desde los proveedores hasta el cliente final.

Dentro de este esquema, la planificación ocupa un rol central, ya que actúa como punto de partida para la coordinación de las demás actividades. En este contexto, el pronóstico de la demanda se convierte en el principal insumo del proceso de planificación, permitiendo alinear las decisiones de abastecimiento, producción y distribución con las necesidades del mercado. Por ende, el forecasting no solo cumple una función predictiva, sino que se posiciona como un elemento integrador facilitando la sincronización entre áreas y contribuyendo a una gestión más eficiente y orientada al servicio.

Dentro de la gestión de operaciones, el pronóstico también funciona como el input principal para procesos de planificación como el Programa Maestro de Producción (MPS) y la planificación de requerimientos de materiales (MRP), determinando las necesidades de aprovisionamiento de materias primas y la programación de la capacidad productiva (Huaca). Asimismo, en entornos de cadenas de suministro integradas, procesos colaborativos como el Sales and Operations Planning (S&OP) o iniciativas de planificación colaborativa entre fabricantes y minoristas permiten mejorar la calidad de la información y reducir el efecto látigo, fenómeno que amplifica la variabilidad de la demanda a medida que se avanza hacia los niveles superiores de la cadena (Ivanov, Tsipoulandis, & Schonberger, 2021).

La literatura también presenta diversos casos empresariales que evidencian la importancia de una gestión efectiva del forecasting en la industria textil. Empresas como Sport Obermeyer lograron reducir significativamente los costos asociados al exceso de inventario y a los quiebres de stock mediante la implementación de procesos formales de pronóstico que combinan análisis estadístico con juicio experto (Nahmias, 2015). De manera similar, compañías como The Gap o Wal-Mart utilizan sistemas de monitoreo continuo de ventas para ajustar sus procesos de reposición y responder con mayor rapidez a las fluctuaciones de la demanda en el punto de venta.

En conjunto, estos ejemplos muestran que el desarrollo de sistemas de pronóstico robustos no solo permite mejorar la eficiencia operativa, sino también reducir desperdicios asociados a la sobreproducción y avanzar hacia modelos de gestión más sostenibles dentro de la industria textil (Kacmary, 2023).

2.2. Métodos estadísticos de pronóstico

Los métodos estadísticos de pronóstico permiten estimar la demanda futura a partir de patrones históricos observados en los datos. A diferencia de los métodos cualitativos, se

basan en relaciones matemáticas objetivas que buscan identificar tendencias, estacionalidades o comportamientos repetitivos a lo largo del tiempo (Makridakis et al., 1998). Estos modelos constituyen la base del pronóstico cuantitativo utilizado en la mayoría de las organizaciones industriales y de consumo masivo.

Dentro de esta categoría, los modelos de series de tiempo utilizan exclusivamente el comportamiento histórico de la variable analizada para generar estimaciones futuras. Como se observa en la Figura. 6, las series de tiempo pueden presentar distintos patrones de comportamiento, tales como fluctuaciones aleatorias, tendencias o combinaciones de tendencia y estacionalidad, los cuales influyen directamente en la selección del método de pronóstico más adecuado.




Figura. 6. Patrones de series de tiempo. Fuente: (Nahmias, 2015).

Bajo este enfoque se asume que los patrones observados en el pasado (como el nivel promedio de la serie, su tendencia o los ciclos estacionales) pueden persistir en el futuro y, por lo tanto, servir como base para la proyección de la demanda. Debido a esta característica, los métodos de series de tiempo son ampliamente utilizados en la planificación operativa de empresas con grandes volúmenes de productos, ya que permiten automatizar pronósticos para miles de artículos o unidades de mantenimiento de stock (SKU) dentro de sistemas de planificación empresarial (Ramírez Agudelo, 2013).

En este sentido, la elección del modelo adecuado depende directamente del comportamiento de la serie de demanda, lo que convierte al análisis previo de patrones en un paso clave dentro del proceso de forecasting.

Por lo tanto, la selección del método de pronóstico no debe realizarse de forma arbitraria, sino en función de la naturaleza de los datos y del objetivo de la planificación. Los modelos estadísticos pueden clasificarse en dos grandes categorías: modelos de series de tiempo y modelos causales. Mientras que los primeros se basan exclusivamente en patrones históricos de la demanda, los segundos incorporan variables externas como el precio, promociones o indicadores macroeconómicos para explicar su comportamiento (Huaca León, 2018).

Desde una perspectiva de planificación, ambos enfoques cumplen roles diferenciados. Los modelos de series de tiempo se aplican principalmente en niveles operativos y tácticos, donde se requiere automatizar pronósticos para grandes volúmenes de SKUs, mientras que los modelos causales se utilizan en niveles estratégicos, donde se busca comprender el impacto de variables externas sobre la demanda.

En este sentido, el pronóstico de demanda no constituye un fin en sí mismo, sino un punto clave dentro del proceso de planificación de la cadena de suministro, particularmente en el marco del Sales and Operations Planning (S&OP).

Como se muestra en la Figura. 7, el pronóstico de demanda actúa como el punto de partida para la toma de decisiones a lo largo de los distintos niveles de planificación, desde el enfoque estratégico hasta la ejecución operativa.



Figura. 7. Diagrama del proceso de S&OP. Fuente: Elaboración propia basado en (Ivanov, Tsipouladis, & Schonberger, 2021).

La figura ilustra cómo el pronóstico de demanda alimenta la planificación de capacidad y la planificación agregada, las cuales se traducen posteriormente en el programa maestro de producción (PMP) y en la planificación de requerimientos de materiales (MRP). A partir de

estos niveles, se derivan decisiones más operativas, como el dimensionamiento de lotes, el aprovisionamiento y la programación a corto plazo.

Este proceso refleja la necesidad de equilibrio entre la demanda y la capacidad disponible en cada etapa de la cadena de suministro, evidenciando el rol central del forecasting como elemento integrador entre las distintas áreas de la organización.

2.2.1. Promedios móviles, suavización exponencial, Holt–Winters, ARIMA

- **Promedios móviles:** El método de promedios móviles calcula el pronóstico como el promedio de los últimos períodos, con el objetivo de suavizar las fluctuaciones aleatorias de corto plazo y estimar el nivel medio de la demanda (Hyndman & Athanasopoulos, 2021).

Desde el punto de vista estadístico, el pronóstico para el período siguiente se obtiene como el promedio aritmético de las últimas N observaciones disponibles. A medida que se incorpora un nuevo dato, el valor más antiguo es eliminado del cálculo, manteniendo constante el tamaño de la ventana de observación (Silver, Pyke, & Thomas, 2016). Este mecanismo implica que todas las observaciones dentro de la ventana tienen el mismo peso, lo que simplifica el cálculo, pero limita la capacidad del modelo para reaccionar rápidamente a cambios recientes en la demanda.

Este método es especialmente adecuado para series estacionarias, es decir, aquellas que oscilan alrededor de un nivel relativamente constante sin presentar tendencias claras ni patrones estacionales definidos (Nahmias, 2015). En este tipo de series, el promedio móvil permite eliminar el ruido aleatorio y revelar el comportamiento subyacente de la demanda.

Como se observa en la Figura. 8, una serie estacionaria fluctúa alrededor de un nivel promedio relativamente constante, donde las variaciones responden principalmente a comportamientos aleatorios y no a cambios estructurales en la demanda.




Figura. 8. Demanda mensual de camisetas con comportamiento estacionario 2020. Fuente: (Valera García, 2022).

En este contexto, el pronóstico se centra en estimar dicho nivel medio a partir de los datos históricos, lo que justifica el uso de métodos como el promedio móvil o la suavización exponencial simple.

Su implementación es sencilla y requiere bajo esfuerzo computacional. Sin embargo, presenta limitaciones importantes en entornos dinámicos, ya que tiende a rezagarse frente a cambios en la demanda; por ejemplo, en contextos como la industria textil, donde las variaciones responden a tendencias de moda o promociones, el método puede generar subestimaciones sistemáticas.

Asimismo, el método requiere almacenar múltiples períodos históricos para cada producto, lo que puede representar una desventaja en sistemas con grandes volúmenes de SKUs.

- **Suavización exponencial:** A diferencia del promedio móvil, la suavización exponencial introduce un sistema de ponderaciones decrecientes para los datos históricos, otorgando mayor peso a las observaciones más recientes. El pronóstico se obtiene mediante una ecuación recursiva que combina la demanda observada con el pronóstico del período anterior, controlada por un parámetro de suavización (α) (Nahmias, 2015). Desde el punto de vista estadístico, el modelo se expresa mediante una ecuación recursiva en la cual el pronóstico se calcula como una combinación entre la demanda observada más reciente y el pronóstico del período anterior. El parámetro de suavización (α) determina la sensibilidad del modelo: valores altos permiten una rápida adaptación a cambios recientes, mientras que valores bajos generan mayor estabilidad frente a variaciones aleatorias.

Esta estructura recursiva implica que no es necesario almacenar grandes volúmenes de datos históricos, ya que el modelo resume la información pasada en el último pronóstico calculado.

Al igual que el promedio móvil, este método es adecuado para series estacionarias sin tendencia ni estacionalidad marcada. Sin embargo, su principal ventaja frente a los promedios móviles radica en su capacidad de reacción, ya que prioriza la información más reciente en el proceso de estimación.

En términos operativos, la suavización exponencial simple es ampliamente utilizada en sistemas ERP (para aplicaciones relativamente estables como repuestos o artículos de mantenimiento) debido a su simplicidad, bajo costo computacional y facilidad de implementación. No obstante, su principal limitación es que no permite capturar componentes de tendencia ni estacionalidad, lo que restringe su aplicación a productos con demanda relativamente estable.

Por esta razón, suele emplearse como base para modelos más avanzados, como los de Holt y Holt–Winters, que incorporan estos componentes adicionales.

- **Modelo de Holt y Holt–Winters:** Los modelos de suavización exponencial de Holt y Holt–Winters constituyen extensiones del método de suavización exponencial simple, diseñadas para capturar componentes adicionales en las series de tiempo, como la tendencia y la estacionalidad. El modelo de Holt (o suavización exponencial doble) incorpora un componente para representar la tendencia de la serie, permitiendo que el pronóstico se ajuste a cambios sostenidos en la demanda a lo largo del tiempo (Hyndman & Athanasopoulos, 2021).

Desde el punto de vista metodológico, este modelo estima simultáneamente el nivel y la tendencia mediante dos parámetros de suavización, lo que permite generar pronósticos que combinan el valor actual de la serie con su dirección de crecimiento o decrecimiento. A diferencia de los métodos más simples, el modelo de Holt no solo considera el nivel histórico de la demanda, sino también la velocidad a la que esta cambia, lo que reduce el rezago en contextos de crecimiento o caída sostenida.

Este modelo resulta adecuado para series con tendencia, pero sin estacionalidad.

Como se observa en la Figura. 9, en una serie con tendencia creciente los métodos simples como el promedio móvil tienden a rezagarse respecto al comportamiento real de la demanda, mientras que el modelo de Holt permite ajustar el pronóstico incorporando la pendiente de crecimiento de la serie.




Figura. 9. Modelo Holt, pronóstico con tendencia creciente. Fuente: Elaboración propia

La figura ilustra cómo el modelo de Holt logra capturar la dirección del crecimiento de la demanda, reduciendo el rezago característico de los métodos que no consideran la tendencia. Esto permite generar pronósticos más precisos en contextos donde la demanda presenta incrementos sostenidos en el tiempo.

En el contexto de la industria textil argentina, este comportamiento puede observarse en escenarios de crecimiento nominal de ventas impulsado por la inflación o en marcas en expansión, donde la demanda presenta una tendencia creciente sostenida. En estos casos, el uso de modelos que incorporen tendencia resulta fundamental para evitar subestimaciones sistemáticas. No obstante, su desempeño depende de una adecuada calibración de los parámetros, ya que valores inadecuados pueden generar sobrereacciones frente a variaciones temporales.

Por su parte, el modelo de Holt–Winters (o suavización exponencial triple) extiende este enfoque al incorporar un tercer componente asociado a la estacionalidad, permitiendo capturar fluctuaciones periódicas en la demanda. Este modelo puede formularse de manera aditiva, cuando la amplitud de las variaciones estacionales es constante, o multiplicativa, cuando dichas variaciones son proporcionales al nivel de la serie (Kacmary, 2023).

La incorporación del componente estacional permite modelar comportamientos recurrentes, como los ciclos de colecciones, cambios climáticos o eventos promocionales, los cuales son característicos de sectores como el retail y la industria textil. Como se observa en la Figura. 10, la demanda presenta fluctuaciones periódicas a lo largo del tiempo, evidenciando patrones recurrentes que se repiten en intervalos regulares. Este comportamiento es característico de series con

estacionalidad, donde los picos y caídas responden a factores como cambios climáticos, temporadas comerciales o eventos promocionales.




Figura. 10. Modelo Holt-winters, Serie de demanda con componente estacional. Fuente: elaboración propia.

En este tipo de series, el modelo de Holt–Winters permite capturar no solo el nivel y la tendencia, sino también los patrones estacionales, ajustando el pronóstico a las variaciones periódicas de la demanda. Esto resulta especialmente relevante en la industria textil, donde los ciclos de colecciones y eventos comerciales generan comportamientos repetitivos en el consumo. En el contexto argentino, estos patrones pueden observarse en los picos asociados a lanzamientos de colecciones de primavera/verano y otoño/invierno, así como en eventos comerciales como el Hot Sale o CyberMonday, los cuales generan incrementos significativos en la demanda en periodos específicos del año.

En este sentido, el modelo Holt–Winters se posiciona como una de las herramientas más completas dentro de la familia de suavización exponencial, al integrar nivel, tendencia y estacionalidad en el proceso de pronóstico (Valera García, 2022). Esta capacidad lo convierte en un modelo altamente utilizado en la planificación de la demanda, especialmente cuando se requiere capturar múltiples patrones simultáneamente.

Sin embargo, una de sus principales limitaciones es que requiere una cantidad suficiente de datos históricos para inicializar correctamente sus componentes. En

general, se recomienda contar con al menos dos ciclos completos de estacionalidad para obtener estimaciones estables.

Asimismo, la complejidad del modelo implica una mayor sensibilidad a la calidad de los datos, por lo que errores o inconsistencias pueden afectar significativamente la precisión del pronóstico.

- **Modelos ARIMA:** Los modelos autorregresivos integrados de medias móviles (ARIMA) constituyen una de las metodologías más avanzadas dentro del análisis de series de tiempo, ya que utilizan tanto los valores pasados de la variable como los errores del modelo para explicar el comportamiento futuro de la demanda (Hyndman & Athanasopoulos, 2021). A diferencia de los métodos de suavización exponencial, estos modelos no se basan en una estructura predefinida, sino que construyen una representación estadística específica a partir de los datos observados.

El enfoque ARIMA se fundamenta en la metodología de Box-Jenkins, la cual propone identificar la estructura de la serie mediante el análisis de sus patrones de autocorrelación y autocorrelación parcial. Esto permite determinar la forma más adecuada del modelo en función del comportamiento histórico de la demanda (Nahmias, 2015).

En este sentido, el proceso de modelado no es automático, sino que requiere una etapa de identificación, estimación y validación del modelo, lo que lo diferencia de otros enfoques más operativos.

El modelo se define a partir de tres parámetros principales: p (componente autorregresivo), d (número de diferenciaciones necesarias para lograr estacionariedad) y q (componente de medias móviles asociado a los errores). La diferenciación (d) cumple un rol clave, ya que permite transformar series no estacionarias en estacionarias, condición necesaria para aplicar este tipo de modelos. El componente autorregresivo (p) implica que el valor actual de la serie puede explicarse como una combinación de sus valores pasados, capturando así la dependencia temporal entre observaciones. En otras palabras, el modelo asume que la demanda tiene “memoria”, es decir, que los valores previos influyen directamente en el comportamiento futuro.

Una de sus principales fortalezas es la capacidad de capturar relaciones complejas entre observaciones de distintos períodos, lo que permite generar pronósticos más precisos en series con patrones temporales sofisticados. Por ello, resulta especialmente útil en contextos donde la demanda presenta comportamientos no lineales o dependencias de largo plazo que no pueden ser

capturadas por modelos más simples. En contextos como la industria textil argentina, donde la demanda puede presentar alta variabilidad debido a cambios de precios, promociones o condiciones macroeconómicas, el análisis de residuos resulta clave para validar si el modelo logra capturar adecuadamente estos comportamientos complejos.

Sin embargo, su implementación requiere un mayor nivel de conocimiento estadístico, así como series de datos relativamente extensas para garantizar estimaciones confiables. Además, es necesario validar supuestos como la estacionariedad, la independencia de los errores y la significancia de los parámetros, lo que puede dificultar su aplicación en entornos operativos (Nahmias, 2015).

En el ámbito empresarial, los modelos ARIMA suelen aplicarse en niveles agregados de planificación, como pronósticos por familia de productos, análisis macroeconómico o planificación de ventas a nivel corporativo. Esto se debe a que su complejidad limita su uso masivo a nivel SKU, donde suelen preferirse métodos más simples y automatizables.

- **Otros modelos relevantes:** Además de los modelos clásicos mencionados, la literatura reciente en forecasting ha incorporado variantes que amplían las capacidades de los modelos de series de tiempo, permitiendo capturar comportamientos más complejos en la demanda y mejorar la precisión de los pronósticos en distintos contextos. Entre ellas destaca el modelo SARIMA (Seasonal ARIMA), que extiende el enfoque ARIMA para capturar patrones estacionales mediante la incorporación de parámetros adicionales asociados a la periodicidad de la serie (Petropoulos, Hyndman, Bergmeir, & Talagala, 2022). Este modelo resulta especialmente útil en series que presentan estacionalidad marcada junto con dependencias temporales complejas, integrando en una sola estructura componentes estacionales y no estacionales.

Otra extensión relevante es el modelo de tendencia amortiguada (Damped Trend), una variación del método de Holt que reduce progresivamente el impacto de la tendencia a medida que el horizonte de pronóstico se aleja en el tiempo. Este enfoque evita proyecciones irreales en el largo plazo, especialmente en mercados donde el crecimiento no puede mantenerse indefinidamente (Hyndman & Athanasopoulos, 2021).

En la práctica, este modelo es particularmente valioso en entornos con alta incertidumbre, donde asumir una tendencia constante puede generar sobreestimaciones significativas.

Finalmente, los modelos de espacio de estados o enfoque ETS (Error, Trend, Seasonality) representan una formulación moderna de los modelos de suavización exponencial. Estos modelos permiten estimar no solo el valor esperado del pronóstico, sino también intervalos de confianza que cuantifican la incertidumbre asociada a las proyecciones (Petropoulos, Hyndman, Bergmeir, & Talagala, 2022).

Esta capacidad de incorporar explícitamente la incertidumbre convierte a los modelos ETS en herramientas especialmente útiles para la toma de decisiones, ya que permiten evaluar no solo el escenario esperado, sino también posibles desviaciones del forecast.

En la práctica, no todos los productos requieren el mismo nivel de precisión en el pronóstico. En este sentido, es importante mencionara la clasificación ABC; que permite segmentar los artículos según su importancia económica, donde un reducido porcentaje de productos (categoría A) concentra la mayor parte de las ventas. Esta segmentación resulta clave para priorizar el uso de modelos más sofisticados en aquellos productos de mayor impacto, optimizando así los recursos analíticos disponibles (Altamirano & Caruso, 2015).

2.2.2. Modelos causales y machine learning

Si bien los modelos tradicionales de series de tiempo han demostrado ser herramientas eficaces para el pronóstico de la demanda, presentan limitaciones al momento de capturar relaciones complejas o incorporar variables externas. En este contexto, los enfoques basados en Machine Learning han emergido como una alternativa complementaria, permitiendo modelar patrones no lineales y mejorar la precisión del pronóstico en entornos altamente dinámicos.

Los modelos causales explican la demanda a partir de la relación con una o más variables independientes que influyen directamente en su comportamiento, como el precio, las promociones, el ingreso del consumidor o indicadores macroeconómicos. A diferencia de los modelos puramente temporales, los causales no se basan solo en patrones históricos, sino en cómo los cambios en dichas variables afectan las ventas (Altamirano & Caruso, 2015). Este enfoque permite simular escenarios (por ejemplo, estimar cómo variaría la demanda ante un ajuste de precios o una campaña comercial), aportando una herramienta útil para la planificación estratégica. En este sentido, la evolución de los enfoques analíticos puede entenderse como un proceso de madurez en la gestión de datos, en el cual las organizaciones avanzan desde la descripción del comportamiento pasado hacia la predicción y optimización de decisiones futuras.




Figura. 11. Niveles de madurez analítica: de la información a la optimización. Fuente: Elaboración propia adaptada de (Jebbor, Benmamoun, & Hachimi, 2024).

Como se observa en la Figura. 11, los modelos tradicionales de análisis se ubican en niveles descriptivos o diagnósticos, centrados en entender qué ocurrió y por qué ocurrió. En contraste, los modelos causales y las técnicas de Machine Learning permiten avanzar hacia niveles predictivos y prescriptivos, al facilitar no solo la anticipación del comportamiento futuro de la demanda, sino también la optimización de decisiones en función de distintos escenarios (Jebbor, Benmamoun, & Hachimi, 2024).

En este sentido, la principal diferencia entre los modelos tradicionales y los enfoques causales radica en la naturaleza de la información utilizada. Mientras que los modelos de series de tiempo (univariados) se basan exclusivamente en datos históricos de la propia demanda, los modelos causales (multivariados) incorporan variables externas que permiten explicar el comportamiento del mercado, no solo predecirlo (Nahmias, 2015). Esta distinción resulta clave en entornos dinámicos, donde la demanda no depende únicamente de su evolución pasada, sino de factores contextuales y decisiones comerciales (Petropoulos, Hyndman, Bergmeir, & Talagala, 2022).

En los últimos años, las técnicas de *Machine Learning* (ML) han ampliado el alcance de este enfoque al incorporar modelos no lineales con capacidad de aprendizaje, como redes neuronales, *random forest* o *gradient boosting*. Estas herramientas permiten capturar interacciones complejas entre múltiples factores, identificar patrones ocultos y mejorar la capacidad predictiva frente a los métodos tradicionales. En la industria textil, su aplicación ha mostrado potencial para anticipar cambios en la demanda por categoría o temporada, optimizar niveles de inventario y apoyar decisiones tácticas sobre surtido y abastecimiento.

A diferencia de los modelos de regresión tradicionales, los algoritmos de Machine Learning no requieren asumir relaciones lineales entre variables, sino que pueden adaptarse a estructuras complejas y detectar patrones no evidentes en grandes volúmenes de datos (Jebbor, Benmamoun, & Hachimi, 2024). Esto resulta especialmente relevante en sectores como el textil y el retail, donde la demanda se ve influenciada por múltiples factores simultáneos y altamente variables (Medina Samaniego, 2021).

En este contexto, la selección adecuada de variables externas se vuelve un elemento crítico para la calidad del pronóstico. Entre las más relevantes se encuentran el precio, las promociones, las condiciones macroeconómicas (como la inflación) y las señales de comportamiento del consumidor, como las tendencias de búsqueda digital (Ivanov, Tsipoulandis, & Schonberger, 2021). La incorporación de estas variables permite capturar de forma más precisa los cambios en la demanda y mejorar la capacidad de anticipación del modelo frente a entornos inestables.

Por lo tanto, los modelos de Machine Learning permiten mejorar la precisión del pronóstico al integrar múltiples variables explicativas, siendo especialmente útiles en entornos complejos donde la demanda no depende únicamente de su comportamiento histórico.

2.2.3. Supuestos de aplicación y requisitos de datos

La efectividad de cualquier modelo de pronóstico depende de la calidad, consistencia y frecuencia de los datos empleados. Los métodos estadísticos se fundamentan en el supuesto de que los patrones históricos reflejan comportamientos futuros y que los errores del modelo son aleatorios e independientes entre sí. Esto implica que los datos no deben presentar sesgos sistemáticos, rupturas estructurales ni alteraciones en la forma en que se registran, ya que cualquiera de estos factores puede distorsionar la estimación de los parámetros y afectar la confiabilidad del forecast. En este sentido, la premisa central de los modelos de series de tiempo es que los componentes de nivel, tendencia y estacionalidad observados en el pasado continuarán en el futuro, lo que constituye la base de su capacidad predictiva (Nahmias, 2015).

Otro supuesto esencial es la estabilidad del proceso generador de datos (*data-generating process*), es decir, que las relaciones subyacentes entre las variables no cambien significativamente a lo largo del tiempo. En contextos de alta volatilidad (como la industria textil, donde inciden estacionalidad, promociones o variaciones económicas), la validez de este supuesto se vuelve especialmente crítica. Cuando se producen cambios abruptos, los modelos deben recalibrarse o complementarse con métodos de juicio experto para reflejar las nuevas condiciones del entorno (Makridakis, Wheelwright, & Hyndman, 1998). Asimismo, muchos modelos asumen condiciones de estacionariedad, especialmente en sus versiones

más simples, donde la demanda oscila alrededor de un valor esperado constante, lo que limita su aplicación en entornos altamente dinámicos (Ramírez Agudelo, 2013).

Respecto a los requisitos de datos, los modelos de series temporales exigen un volumen mínimo de observaciones continuas para capturar adecuadamente los componentes de nivel, tendencia y estacionalidad. En términos generales, se recomienda disponer de al menos dos ciclos completos del patrón estacional (por ejemplo, 24 meses para datos mensuales con estacionalidad anual) para garantizar estimaciones estables. Cuando se trabaja con frecuencias mayores (semanales o diarias), el criterio se mantiene: cubrir al menos dos repeticiones del ciclo estacional que se desea modelar (Hyndman & Athanasopoulos, 2021). En el caso de modelos más complejos como ARIMA, se recomienda contar con al menos 72 observaciones históricas para asegurar estimaciones robustas. Asimismo, los datos deben registrarse en intervalos equidistantes y mantener consistencia en su estructura temporal, evitando cambios en la forma de captura o definición de las variables (Altamirano & Caruso, 2015). Adicionalmente, otro supuesto relevante en la planificación de la demanda es el principio de agregación, según el cual los pronósticos a nivel agregado (por familia de productos) tienden a ser más precisos que los pronósticos individuales por SKU, debido a la compensación de errores entre series individuales. En el contexto de la industria textil, este principio cobra especial relevancia, ya que la alta variabilidad a nivel de SKU (producto de combinaciones de talla, color y modelo) puede generar series altamente erráticas y difíciles de modelar de forma individual. Por ello, en la práctica, resulta más robusto realizar el pronóstico a un nivel agregado (por categoría o familia de productos) y posteriormente desagregarlo hacia niveles más específicos mediante enfoques top-down, utilizando ponderaciones basadas en la participación histórica de cada SKU. Este enfoque permite reducir el sesgo asociado a la volatilidad individual de los productos, logrando una distribución más estable y coherente del forecast dentro del portafolio.

En la práctica, uno de los principales desafíos en la aplicación de modelos de pronóstico es la calidad de los datos utilizados. En particular, el uso de ventas históricas como proxy de la demanda real puede generar sesgos cuando existen quiebres de stock, ya que las ventas observadas no reflejan la demanda insatisfecha, produciendo lo que se conoce como datos censurados, tal como se explicó en la sección 2.1.2. Este fenómeno genera una subestimación sistemática tanto del nivel promedio como de la variabilidad de la demanda, lo que puede derivar en políticas de inventario inadecuadas. Asimismo, eventos como promociones, cambios de precios o interrupciones en el abastecimiento pueden introducir distorsiones que deben ser identificadas y ajustadas antes de alimentar los modelos. Por ejemplo, las campañas promocionales o liquidaciones de temporada generan picos de

demanda que no responden a un patrón estructural, sino a decisiones comerciales específicas, por lo que deben ser tratadas mediante ajustes manuales o mediante la incorporación de variables exógenas en modelos causales (Jebbor, Benmamoun, & Hachimi, 2024). De igual forma, la presencia de valores atípicos (outliers), originados por eventos excepcionales como crisis logísticas, huelgas o shocks externos, puede distorsionar la identificación de patrones si no se filtran adecuadamente durante el proceso de preparación de datos. En contextos como el argentino, caracterizados por alta inflación y volatilidad macroeconómica, pueden producirse cambios estructurales en la demanda que invalidan los patrones históricos. Estos cambios de régimen generan errores sistemáticos en los modelos si no son detectados oportunamente, lo que refuerza la necesidad de complementar los modelos estadísticos con criterio experto (Silver, Pyke, & Thomas, 2016).

Adicionalmente, la evaluación del desempeño del pronóstico mediante indicadores cuantitativos como el error porcentual absoluto medio (MAPE) o el sesgo (bias) resulta fundamental para monitorear la calidad del modelo y detectar desviaciones sistemáticas. Estas métricas permiten no solo medir la precisión del forecast, sino también identificar si el modelo tiende a sobreestimar o subestimar la demanda de manera consistente.

En todos los casos, la evaluación periódica del error y la revisión sistemática del modelo son indispensables para asegurar la confiabilidad del proceso de pronóstico y su adaptación a los cambios del entorno. La omisión de estas prácticas puede derivar en errores acumulativos, pérdida de exactitud y decisiones operativas incorrectas en la planificación de la demanda.

Por lo tanto, el proceso de forecasting no se limita únicamente a la aplicación de un modelo estadístico, sino que implica una secuencia estructurada de etapas que permiten transformar datos en decisiones operativas. Como se muestra en la Figura. 12. Proceso de forecasting: desde la recolección de datos hasta la sincronización en S&OP. Fuente: Elaboración propia. , un proceso robusto de pronóstico integra desde la recolección y preparación de los datos hasta la validación del modelo y su posterior incorporación en la planificación de la cadena de suministro.




Figura. 12. Proceso de forecasting: desde la recolección de datos hasta la sincronización en S&OP. Fuente: Elaboración propia.

El proceso inicia con la recolección de datos provenientes de sistemas transaccionales, tales como ventas históricas, inventarios y variables externas relevantes. Posteriormente, se realiza una etapa crítica de preprocesamiento y limpieza, en la cual se corrigen distorsiones como valores atípicos, datos faltantes y demanda censurada. A partir de estos datos depurados, se procede a la identificación de patrones, donde se analizan componentes como nivel, tendencia y estacionalidad, fundamentales para la selección del modelo adecuado.

En función de estos patrones, se selecciona e inicializa el modelo de pronóstico, ajustando sus parámetros según el comportamiento de la serie. Una vez generado el forecast, este puede ser complementado mediante juicio experto, especialmente en contextos donde

existen eventos futuros no reflejados en los datos históricos, como promociones o cambios en tendencias de moda.

Finalmente, el modelo es evaluado mediante métricas de error y monitoreado de forma continua, permitiendo su ajuste y mejora en el tiempo. El resultado del proceso se integra en el ciclo de planificación S&OP, donde el pronóstico se utiliza como insumo clave para la toma de decisiones en producción, compras e inventarios, cerrando así el ciclo entre análisis de datos y ejecución operativa.

2.3. Variables críticas en el sector textil

El comportamiento de la demanda en la industria textil se caracteriza por una alta volatilidad, marcada estacionalidad y fuerte influencia de factores externos como la moda, los ciclos económicos y el clima. Estas particularidades obligan a que los modelos de pronóstico incorporen supuestos y ajustes específicos para capturar cambios frecuentes en los patrones de consumo y en los niveles de inventario.

Por lo tanto, la precisión del forecast no depende únicamente de la selección del modelo estadístico, sino también de la correcta identificación e incorporación de variables críticas propias del sector. Dichas variables condicionan tanto la forma de la demanda como la interpretación de los datos históricos, requiriendo ajustes metodológicos específicos para capturar adecuadamente la dinámica del mercado textil.

A diferencia de otras industrias con patrones de consumo más estables, el sector textil presenta una elevada sensibilidad frente a factores como la estacionalidad, las tendencias de moda, las promociones comerciales y las variaciones macroeconómicas (Altamirano & Caruso, 2015). Estas variables impactan directamente en la planificación de inventarios, la programación de producción y las decisiones de abastecimiento dentro de la cadena de suministro.

Asimismo, las características propias de esta industria, como los ciclos de vida cortos de los productos, la coexistencia entre artículos básicos y lanzamientos de temporada, así como la presencia de ventas pérdidas ocasionadas por quiebres de stock, incrementan la complejidad del proceso de forecasting y obligan a utilizar enfoques de planificación más flexibles y adaptativos (Nahmias, 2015).

En este contexto, resulta muy importante analizar las principales variables críticas que condicionan el comportamiento de la demanda en la industria textil, así como los supuestos y requisitos necesarios para la correcta y eficiente aplicación de modelos de pronóstico dentro de entornos altamente dinámicos y volátiles.

2.3.1. Estacionalidad, lanzamientos vs. Básicos

La industria textil presenta características particulares que diferencian significativamente su comportamiento de demanda respecto de otros sectores productivos. Entre los principales factores que condicionan la planificación y el forecasting destacan la estacionalidad, la sensibilidad climática y la coexistencia entre productos básicos y productos de lanzamiento o moda (Altamirano & Caruso, 2015). Estas variables generan patrones de consumo altamente dinámicos, obligando a las organizaciones a adaptar continuamente sus estrategias de abastecimiento, producción e inventarios.

Esto conlleva a que la correcta identificación del tipo de producto y de los patrones estacionales asociados jueguen un papel fundamental para mejorar la precisión de los pronósticos y reducir riesgos operativos como sobrestock, quiebres de inventario u obsolescencia de productos.

2.3.1.1. Estacionalidad y clima

La estacionalidad constituye uno de los principales factores que afectan el comportamiento de la demanda en la industria textil. Los patrones de consumo suelen repetirse de manera periódica en función de las estaciones del año, las colecciones de invierno y verano, así como determinados eventos comerciales o períodos vacacionales (Nahmias, 2015).

Asimismo, es importante tener en cuenta las variaciones que pueden generar las condiciones climáticas en el comportamiento de compra de los consumidores. Cambios inesperados de temperatura pueden alterar drásticamente la demanda proyectada de determinadas categorías de productos, incluso de colecciones enteras; repercutiendo directamente en las ganancias. Por ejemplo, un invierno más cálido de lo previsto puede reducir considerablemente las ventas de prendas de abrigo, ocasionando excesos de inventario y posteriores liquidaciones con descuentos (Altamirano & Caruso, 2015).

Desde el punto de vista operativo, la estacionalidad condiciona la programación de producción, la planificación de abastecimiento y la distribución de inventarios dentro de la

cadena de suministro. Por esta razón, las empresas textiles suelen trabajar con modelos estadísticos capaces de capturar componentes estacionales y tendencias simultáneamente, como los modelos Holt-Winters o factores estacionales multiplicativos (Kacmary, 2023).

En países como Argentina, la estacionalidad también se relaciona con comportamientos regionales y períodos turísticos específicos, generando picos de demanda en determinadas ciudades o zonas comerciales durante ciertas épocas del año (Altamirano & Caruso, 2015).

2.3.1.2. Productos Básicos y lanzamientos

Dentro de la industria textil coexisten dos grandes categorías de productos con comportamientos de demanda diferenciados: los productos básicos o de colección y los productos de lanzamiento o moda estacional. Esta segmentación resulta relevante debido a que cada tipo de artículo requiere enfoques de planificación y forecasting distintos.

Los productos básicos corresponden a artículos de demanda relativamente estable y recurrente, tales como prendas esenciales o líneas permanentes que permanecen activas durante largos períodos de tiempo. Debido a su continuidad comercial, estos productos cuentan con mayor disponibilidad de información histórica, permitiendo la utilización de modelos estadísticos tradicionales basados en series de tiempo y análisis de tendencias.

Por otro lado, los productos de lanzamiento poseen ciclos de vida considerablemente más cortos y suelen estar asociados a tendencias de moda o colecciones temporales (Kacmary, 2023). En muchos casos, estos artículos permanecen disponibles únicamente durante una temporada y no vuelven a comercializarse posteriormente, reduciendo significativamente la disponibilidad de datos históricos comparables.

Esta situación incrementa la incertidumbre del forecast y eleva el riesgo de obsolescencia e inventarios excedentes si la demanda real resulta inferior a la proyectada. Por ello, las empresas suelen complementar los métodos cuantitativos tradicionales con juicio experto, análisis de tendencias y monitoreo temprano del comportamiento de ventas durante las primeras semanas de comercialización (Altamirano & Caruso, 2015). Para los productos de lanzamiento, al no contar con historial de ventas, es común utilizar técnicas de analogía o productos espejo, consistentes en asignar al nuevo artículo el comportamiento histórico de productos similares en términos de categoría, estacionalidad, segmento o patrón de consumo. En otros casos, se emplean curvas de comportamiento esperadas basadas en artículos comparables, ajustando posteriormente el volumen total proyectado mediante juicio experto.

o criterios comerciales definidos por el área de planificación. Estas metodologías permiten reducir parcialmente la incertidumbre asociada al lanzamiento de nuevos productos dentro de entornos de alta volatilidad.

Asimismo, empresas del sector fast fashion, como Zara, implementan estrategias de abastecimiento flexible y producción parcial inicial para reaccionar rápidamente a los cambios de tendencia del mercado durante la temporada. Este enfoque permite reducir el riesgo asociado a la volatilidad de la demanda y minimizar niveles de sobrestock en productos de corta vida comercial (Altamirano & Caruso, 2015).

2.3.2. Supuestos de uso y requisitos de entrada en industria textil

2.3.2.1. Calidad y preparación de datos

La aplicación de modelos de forecasting requiere contar con información histórica confiable, consistente y representativa del comportamiento real de la demanda (Nahmias, 2015). Entre los principales datos utilizados en procesos de planificación se encuentran los históricos de ventas, niveles de inventario, promociones comerciales, quiebres de stock y variables externas relacionadas con el comportamiento del mercado.

Sin embargo, la información utilizada en procesos de forecasting suele presentar distorsiones ocasionadas por errores operativos, eventos atípicos o comportamientos no recurrentes, haciendo necesario realizar procesos previos de depuración y validación de datos antes de ejecutar modelos estadísticos.

Estas actividades de limpieza y preprocesamiento incluyen la identificación de valores atípicos, tratamiento de datos faltantes, corrección de errores de carga y ajustes asociados a promociones extraordinarias o liquidaciones de temporada (identificación de eventos puntuales). La ausencia de estas validaciones puede modificar significativamente los patrones históricos interpretados por los modelos estadísticos y afectar la precisión del forecast.

Asimismo, debido a la constante incorporación y discontinuación de artículos dentro del portafolio textil, las organizaciones suelen requerir procesos continuos de homologación, actualización y mantenimiento de información antes de ejecutar modelos predictivos o análisis de demanda.

2.3.2.2. Demanda censurada y ventas perdidas

Como se desarrolló previamente en el apartado 2.1.2, las ventas históricas no siempre representan la demanda real del mercado, especialmente en contextos donde existen

quiebres de stock o restricciones de abastecimiento (Nahmias, 2015). En estos casos, los registros observados contienen información parcial de la demanda, fenómeno conocido como demanda censurada.

Desde la perspectiva del forecasting, esta situación genera sesgos relevantes en los modelos estadísticos, ya que el uso exclusivo de ventas históricas puede conducir a subestimaciones sistemáticas de la demanda futura. Por ello, resulta necesario identificar períodos afectados por faltantes de inventario e incorporar ajustes o estimaciones complementarias que permitan aproximarse de manera más precisa al comportamiento real del mercado.

La consideración de ventas perdidas adquiere especial relevancia en productos de alta rotación, artículos promocionales y lanzamientos, donde un quiebre de stock puede ocultar oportunidades significativas de venta y afectar directamente la planificación de abastecimiento e inventarios.

2.3.3. Segmentación de clientes, márgenes y poder adquisitivo como variable macroeconómica.


La demanda en la industria textil no presenta un comportamiento homogéneo entre todos los clientes, canales o categorías de productos. Por lo tanto, los procesos de forecasting suelen requerir segmentaciones que permitan diferenciar patrones de consumo, niveles de rotación y sensibilidad frente al precio o a las promociones.


Una de las segmentaciones más utilizadas dentro de la planificación de demanda corresponde al análisis por categorías de producto, canales comerciales o nivel de rotación. Esta clasificación permite identificar artículos estratégicos, productos de alta variabilidad o referencias con mayor impacto sobre las ventas y los inventarios, facilitando la asignación de distintos criterios de planificación y abastecimiento según las características de cada grupo. Por ejemplo, los distintos canales comerciales pueden presentar comportamientos de demanda diferenciados según el tipo de producto comercializado. En algunos casos, clientes mayoristas tienden a concentrar sus compras en productos básicos de colección o líneas de alta rotación, priorizando volumen, continuidad y estabilidad de abastecimiento. Por el contrario, canales minoristas, tiendas departamentales o formatos orientados al fast fashion suelen presentar una mayor participación de lanzamientos, colecciones de temporada y productos asociados a tendencias de moda, generando patrones de demanda más variables y sensibles a cambios del mercado. Esta segmentación permite ajustar estrategias de forecasting, inventarios y reposición según las características específicas de cada canal comercial.

Asimismo, determinados segmentos de clientes presentan comportamientos de consumo significativamente más sensibles frente a cambios de precio, promociones o variaciones del poder adquisitivo. En contextos inflacionarios, como el argentino, esta situación genera modificaciones frecuentes en los patrones de compra, priorización de productos esenciales y migración hacia categorías de menor precio o mayor descuento (INDEC, 2024). Por lo que, eventos comerciales como Hot Sale, CyberMonday o liquidaciones de temporada generan incrementos temporales en la demanda y alteraciones en el comportamiento habitual de consumo que se deben tener en cuenta en la planificación para realizar los ajustes requeridos al modelo (Ivanov, Tsipoulandis, & Schonberger, 2021).

Por otro lado, el análisis de márgenes también adquiere relevancia dentro de la planificación de demanda, ya que no todos los productos poseen el mismo impacto económico para la organización. En muchos casos, las empresas priorizan niveles de servicio más altos para categorías estratégicas o artículos de mayor rentabilidad, ajustando sus políticas de inventario y abastecimiento según el valor financiero de cada segmento. La incorporación de variables macroeconómicas y comerciales dentro del análisis de demanda permite complementar los modelos estadísticos tradicionales y mejorar la interpretación de cambios en el comportamiento del mercado, especialmente en entornos caracterizados por alta incertidumbre y fluctuaciones del consumo. El poder adquisitivo, por lo tanto, constituye una variable macroeconómica de especial relevancia para el proceso de forecasting, ya que puede utilizarse para complementar modelos causales, construir escenarios de planificación y ajustar decisiones relacionadas con compras, inventarios y capacidad productiva pues influye directamente sobre la capacidad de compra de los consumidores. Su incorporación permite interpretar de forma más precisa las variaciones del consumo y fortalecer el proceso de toma de decisiones dentro del demand planning (Braun & Llach, 2010).

Figura 2. Relación entre el poder adquisitivo y la planificación de la demanda





Fuente: Elaboración propia

Como se observa en la Figura 2, una mejora en el poder adquisitivo incrementa la capacidad de compra de los consumidores, favoreciendo un comportamiento de demanda más estable y predecible. Esto permite elaborar pronósticos con mayor precisión, optimizar la planificación de la producción e inventarios y mejorar la utilización de la capacidad instalada, contribuyendo finalmente a la reducción de costos operativos.

2.4. Métricas de evaluación de precisión

La evaluación de la precisión del forecast constituye una etapa fundamental dentro de los procesos de planificación de demanda, ya que permite medir el desempeño de los modelos utilizados y determinar qué metodología representa de manera más adecuada el comportamiento de la demanda en cada caso (Hyndman & Athanasopoulos, 2021).

El error de pronóstico se define como la diferencia entre la demanda real y el valor proyectado para un período determinado. A partir de esta diferencia, es posible construir distintas métricas orientadas a evaluar la magnitud, variabilidad y comportamiento de los errores generados por los modelos de forecasting. Estas métricas permiten comparar metodologías, monitorear desviaciones y mejorar la toma de decisiones dentro de la cadena de suministro.

Las métricas de precisión pueden clasificarse principalmente en métricas absolutas y métricas porcentuales. Mientras las métricas absolutas expresan el error en las mismas unidades físicas de la demanda, las métricas porcentuales permiten comparar resultados entre productos o categorías con diferentes niveles de volumen.

2.4.1. MAPE, WAPE, MAE, RMSE y rangos de referencia

Las principales métricas utilizadas para evaluar la precisión del forecast se resumen en la **¡Error! No se encuentra el origen de la referencia.:**

Tabla 3. Principales métricas de evaluación de precisión del forecast

Métrica	Fórmula	Interpretación	Limitaciones
MAE (Mean Absolute Error)	$MAE = \sum A_t - F_t / n$	Representa el promedio de errores absolutos en las mismas unidades de la demanda.	No penaliza significativamente errores extremos.
RMSE (Root Mean Squared Error)	$RMSE = \sqrt{[\sum (A_t - F_t)^2 / n]}$	Mide la magnitud del error otorgando mayor peso a desviaciones grandes.	Puede verse fuertemente afectado por outliers.
MAPE (Mean Absolute Percentage Error)	$MAPE = (100/n) \times \sum (A_t - F_t) / A_t $	Expresa el error promedio en términos porcentuales respecto a la demanda real.	Presenta distorsiones con demandas bajas o iguales a cero.
WAPE (Weighted Absolute Percentage Error)	$WAPE = \sum A_t - F_t / \sum A_t$	Mide el error porcentual total ponderado según el volumen de demanda.	Puede ocultar errores relevantes en productos de bajo volumen.

Fuente: elaboración propia adaptado de (Hyndman & Athanasopoulos, 2021).

Las métricas MAE y RMSE corresponden a indicadores absolutos, ya que expresan el error en las mismas unidades que la demanda real. Estas métricas permiten evaluar directamente el impacto operativo de las desviaciones del forecast sobre inventarios, producción o abastecimiento.

El MAE (Mean Absolute Error) representa el promedio de los errores absolutos del pronóstico y facilita la interpretación del desvío promedio respecto a la demanda observada (Silver, Pyke, & Thomas, 2016). Debido a su simplicidad, suele utilizarse para analizar el impacto del error en términos físicos, como unidades de producto, prendas o niveles de inventario.

Por otro lado, el RMSE (Root Mean Squared Error) incorpora una penalización cuadrática sobre los errores, otorgando mayor peso a desviaciones extremas. Como consecuencia, esta métrica resulta útil en escenarios donde errores elevados generan impactos significativos sobre costos operativos, quiebres de stock o sobre-inventarios (Hyndman & Athanasopoulos, 2021).

A diferencia de las métricas absolutas, el MAPE (Mean Absolute Percentage Error) y el WAPE (Weighted Absolute Percentage Error) expresan el error en términos porcentuales, permitiendo comparar el desempeño del forecast entre productos o categorías con distintos volúmenes de venta.

El MAPE calcula el error promedio relativo respecto a la demanda observada y es ampliamente utilizado debido a su facilidad de interpretación. Sin embargo, presenta limitaciones importantes en productos con demanda baja o períodos con ventas iguales a cero, ya que puede generar distorsiones significativas en los resultados (Petroopoulos, Hyndman, Bergmeir, & Talagala, 2022). Por esta razón, muchas organizaciones utilizan el WAPE como indicador principal dentro de procesos de supply chain y demand planning. Esta métrica pondera el error utilizando el volumen total de demanda como denominador, reduciendo las distorsiones generadas por productos de bajo volumen o demandas cercanas a cero.

Asimismo, resulta importante diferenciar la precisión del forecast respecto al sesgo o bias. Mientras la precisión evalúa qué tan cerca se encuentra el pronóstico de la demanda real (que tan grande es el error), el sesgo indica la tendencia sistemática del modelo a sobreestimar o subestimar la demanda (hacia donde se equivoca el forecast) (Altamirano & Caruso, 2015).

En la práctica, las organizaciones suelen utilizar rangos de referencia para interpretar el desempeño de los modelos de forecasting. En industrias con alta estacionalidad y variabilidad, como la textil, errores inferiores al 10% suelen considerarse excepcionales, mientras que rangos entre 10% y 20% son generalmente aceptados para procesos de planificación. Por el contrario, errores superiores al 50% suelen indicar que el modelo no representa adecuadamente el comportamiento de la demanda o que existen variables relevantes no incorporadas dentro del análisis (Kacmary, 2023).

Dentro de la industria textil argentina, el monitoreo continuo de métricas de precisión adquiere especial relevancia debido a la volatilidad del consumo, la sensibilidad frente a promociones y la rápida rotación de productos. En este contexto, el seguimiento de indicadores como MAPE o WAPE permite mejorar la toma de decisiones relacionadas con abastecimiento,


inventarios y planificación de colecciones, reduciendo la dependencia exclusiva del juicio empírico dentro de los procesos de forecasting.

2.5. Industria textil y entorno VUCA

La planificación de la demanda en la industria textil se desarrolla en un entorno caracterizado por altos niveles de volatilidad, incertidumbre, complejidad y ambigüedad. El concepto VUCA describe escenarios donde factores económicos, comerciales y operativos modifican constantemente las condiciones del mercado, dificultando la estabilidad de los procesos de forecasting y planificación (Mohd Aris, Sarah Omar, & Hashim, 2014).

En este contexto, las organizaciones requieren mecanismos de análisis y toma de decisiones que permitan responder de manera más flexible frente a cambios abruptos de demanda, variaciones del consumo y interrupciones dentro de la cadena de suministro.

Figura. 13. Esquema entorno VUCA



Fuente: Elaboración propia

Dentro de estos entornos, la evolución del poder adquisitivo también constituye una de las principales fuentes de incertidumbre para la planificación de la demanda, debido a que altera rápidamente el comportamiento del consumidor y dificulta la estabilidad de los patrones históricos utilizados por los modelos de pronóstico.

2.5.1. Implicancia de la volatilidad e incertidumbre

En la industria textil argentina, la volatilidad macroeconómica y la variabilidad del consumo generan condiciones de planificación altamente cambiantes. Factores como inflación, modificaciones del poder adquisitivo, promociones comerciales y cambios rápidos de

tendencia reducen la previsibilidad de la demanda y obligan a trabajar con horizontes de planificación más cortos.

Asimismo, la variabilidad de la demanda incrementa el riesgo de errores de forecasting y provoca desajustes entre producción, inventarios y consumo real (Kacmary, 2023). Estas desviaciones pueden amplificarse a lo largo de la cadena de suministro mediante el efecto látigo, generando sobrestock, quiebres de inventario y mayores costos operativos (Nahmias, 2015).

Frente a este escenario, la literatura destaca la importancia de desarrollar cadenas de suministro resilientes y flexibles. La resiliencia se relaciona con la capacidad de recuperación frente a disrupciones, mientras que la flexibilidad permite adaptar rápidamente procesos, abastecimiento y niveles de inventario ante cambios del entorno (Ejemplo: esquema de producción nacional + importaciones) (Ivanov, Tsipoulandis, & Schonberger, 2021).

2.5.2. Rol de escenarios teóricos para evaluar robustez del forecast

Ante entornos de alta incertidumbre, las organizaciones suelen utilizar escenarios teóricos y simulaciones para evaluar el comportamiento del forecast bajo diferentes condiciones de demanda. Estos escenarios permiten realizar análisis de tipo “what-if”, facilitando la evaluación de riesgos y la toma de decisiones dentro de los procesos de planificación (Mora García, 2010).

La robustez del forecast se relaciona con la capacidad del modelo para mantener resultados aceptables frente a variaciones en los supuestos de entrada o cambios abruptos del mercado. Para ello, generalmente se utilizan escenarios base, optimistas y pesimistas que permiten anticipar distintos comportamientos posibles de la demanda.

La incertidumbre dentro de la cadena de suministro textil puede originarse en distintos factores asociados a la demanda, el entorno económico, el abastecimiento o los propios procesos de planificación como se muestra en la Tabla 4. La identificación de estas fuentes de incertidumbre permite evaluar riesgos operativos y desarrollar escenarios de simulación más representativos para la toma de decisiones.

Tabla 4. Tipos de incertidumbre y su impacto en la supply chain textil

Tipo de incertidumbre	Factor asociado	Impacto operativo
Demanda	Moda, promociones, clima	Variabilidad y quiebres de stock
Económica	Inflación, tipo de cambio	Cambios de consumo y márgenes

Suministro	Restricciones logísticas	Retrasos y faltantes
Planificación	Error forecast	Desalineación operativa

Fuente: Elaboración propia adaptado de (Ivanov, Tsipoulidis, & Schonberger, 2021).

Dentro de los procesos de S&OP, estas simulaciones permiten realizar análisis de sensibilidad y stress testing de demanda, identificando el impacto que diferentes niveles de error pueden generar sobre inventarios, abastecimiento o nivel de servicio. Como resultado, las organizaciones pueden definir estrategias de contingencia y ajustar de manera anticipada sus políticas operativas frente a posibles variaciones del mercado.

2.6. Revisión de estudios previos

La literatura aplicada relacionada con forecasting y planificación de demanda evidencia una transición progresiva desde enfoques empíricos hacia metodologías cuantitativas y analíticas dentro de la industria textil y retail. Diversos estudios nacionales e internacionales coinciden en que la incorporación de herramientas estadísticas, modelos predictivos y procesos estructurados de planificación permite mejorar la precisión del forecast y optimizar la toma de decisiones operativas.

2.6.1. Casos relevantes en la industria textil (nacional e internacional)

En el ámbito nacional, el estudio desarrollado por Altamirano y Caruso (2015) sobre una PyME textil en Mar del Plata, Argentina, destaca por abordar la falta de información histórica mediante la integración de simulación Monte Carlo y el Proceso Analítico Jerárquico (PAJ). Las autoras demostraron que el uso de estas herramientas permitió reducir significativamente el error de pronóstico y mejorar la alineación entre producción y demanda real (Altamirano & Caruso, 2015).

En Latinoamérica, distintas investigaciones refuerzan la aplicación de metodologías estadísticas dentro de procesos de planificación textil. Huaca León (2018) en Colombia y Valera García (2022) en Perú implementaron modelos de suavización exponencial y clasificación ABC en empresas de indumentaria deportiva. En el caso peruano, se reportó una reducción del 43% en costos asociados a quiebres de stock y del 19% en costos de sobrestock (Valera García, 2022).

Por su parte, Medina Samaniego (2021) en Ecuador incorporó algoritmos de Machine Learning combinados con datos provenientes de Google Trends, evidenciando mejoras de precisión entre 5% y 20% frente a modelos univariados tradicionales en entornos de alta volatilidad. La Tabla 5 sintetiza la evidencia empírica específica que sustenta la problemática

diagnosticada en cada uno de estos casos, mostrando cómo la ausencia de herramientas estadísticas formales se tradujo en limitaciones concretas de gestión y planificación en cada organización.

Tabla 5. Evidencia empírica del problema diagnosticado en los estudios revisados

Autor (Año)	Problema / situación diagnosticada	Evidencia encontrada
Altamirano & Caruso (2015)	Escasez de datos históricos confiables y dependencia del juicio experto para la toma de decisiones	Decisiones centralizadas en el dueño y sustentadas en su experiencia; registros de ventas distribuidos en 96 planillas Excel
Valera García (2022)	Planificación reactiva de la producción y deficiente gestión de inventarios	No existe un área formal de planeamiento; la producción se define en base a pedidos recibidos, con desviaciones del pronóstico fuera de los límites aceptables
Huaca León (2018)	Deficiencias en la planificación asociadas a rupturas de stock e incumplimientos de despacho	Dependencia del juicio del administrador en el forecasting y procesamiento manual en Excel de información extraída del ERP
Medina Samaniego (2021)	Alta volatilidad de mercado, calidad deficiente de datos y limitaciones de los modelos tradicionales	Más del 30% de datos faltantes y dificultad para captar información contextual

Fuente: Elaboración propia

A nivel internacional, el caso de Sport Obermeyer, documentado por Fisher et al. (1994), constituye uno de los referentes más reconocidos dentro del forecasting aplicado a la industria de indumentaria. Mediante la combinación de juicio experto y modelos de respuesta rápida, la empresa logró reducir sus costos asociados a errores de forecast del 10.2% al 1.8% de las ventas.

Asimismo, investigaciones aplicadas en cadenas globales de retail utilizando modelos ARIMA y algoritmos de Machine Learning reportan reducciones consistentes de sobrestock y mejoras en la sincronización entre demanda e inventarios, disminuyendo el impacto financiero asociado a la sobreproducción (Vivas, 2025).

Al contrastar estos casos entre sí, se observa una tendencia común hacia el abandono progresivo de los métodos puramente empíricos en favor de herramientas cuantitativas, independientemente del país o del tamaño de la organización. Sin embargo, esta convergencia no implica homogeneidad metodológica: mientras que estudios como los de

Altamirano y Caruso (2015) o Huaca León (2018) se desarrollan en PyMEs con escasa disponibilidad de datos históricos y recurren a la simulación o a modelos de suavización relativamente simples, casos como el de Medina Samaniego (2021) incorporan Machine Learning y fuentes de datos externas, lo que sugiere que la sofisticación del método aplicado responde más a la madurez analítica y a la disponibilidad de información de cada organización que a una superioridad intrínseca de un enfoque sobre otro. Asimismo, cabe señalar que la mayoría de estos estudios corresponde a casos únicos documentados en un momento específico, sin réplicas posteriores ni comparaciones bajo condiciones controladas, lo que limita la posibilidad de generalizar sus resultados más allá del contexto en el que fueron obtenidos.

2.6.2. Resultados reportados: mejoras de precisión, lecciones aprendidas

Los estudios revisados coinciden en que la incorporación de modelos estadísticos y herramientas analíticas mejora significativamente la precisión del forecast y contribuye a optimizar la planificación operativa dentro de la cadena de suministro textil.

Uno de los principales hallazgos corresponde a la importancia de la calidad de datos y la corrección de sesgos asociados a ventas perdidas o demanda censurada. Diversos autores señalan que el uso exclusivo de ventas históricas sin ajustes adecuados genera subestimaciones sistemáticas de la demanda real y afecta directamente la precisión de los modelos (Nahmias, 2015).

Asimismo, la literatura destaca que la precisión estadística resulta insuficiente si no se encuentra integrada dentro de procesos colaborativos de planificación como S&OP. La coordinación entre áreas comerciales, operaciones y finanzas permite complementar los modelos cuantitativos y mejorar la toma de decisiones frente a escenarios de incertidumbre (Vivas, 2025).

Otro aspecto recurrente en los estudios analizados corresponde a la superioridad de los modelos cuantitativos respecto a enfoques basados únicamente en juicio experto. Si bien la experiencia gerencial continúa siendo relevante para eventos excepcionales o lanzamientos específicos, las metodologías estadísticas permiten reducir sesgos subjetivos y mejorar la consistencia de las proyecciones en horizontes de planificación recurrentes.

Varios autores coinciden en la necesidad de complementar el forecast base con escenarios alternativos y análisis de sensibilidad, especialmente en contextos volátiles como el argentino. La utilización de escenarios optimistas, pesimistas y base permite evaluar la robustez de las políticas de inventario y anticipar posibles impactos operativos frente a cambios bruscos de demanda o consumo.

Tabla 6. Resumen de estudios previos en forecasting textil y retail

Autor / Estudio	Industria o Empresa	Metodología utilizada	Resultado principal
Altamirano & Caruso (2015)	PyME Textil (Argentina)	Simulación Monte Carlo y PAJ	Reducción significativa del error de forecast y mejora en la planificación.
Valera García (2022)	Tex Javier Sport (Perú)	Suavización exponencial y análisis ABC	Reducción del 43% en quiebres y 19% en sobrestock.
Medina Samaniego (2021)	MiPymes textiles (Ecuador)	Machine Learning + Google Trends	Mejora de precisión entre 5% y 20%.
Huaca León (2018)	Sector textil (Colombia)	Suavización exponencial doble	Optimización de reposición y reducción de quiebres.
Fisher et al. (1994) – Sport Obermeyer	Indumentaria (Internacional)	Juicio experto y respuesta rápida	Reducción de costos por error de forecast del 10.2% al 1.8%.
Cachon & Terwiesch (2019)	Retail global	ARIMA y Machine Learning	Reducción de sobrestock entre 10% y 20%.
Boada (2017)	Venta por catálogo	Modelo bayesiano y regresión múltiple	Automatización de proyecciones para productos de ciclo corto.

Fuente: Elaboración propia adaptado de los estudios revisados.

Como se ve en la Tabla 6, los estudios analizados evidencian que la incorporación de herramientas estadísticas, metodologías analíticas y procesos estructurados de planificación contribuye significativamente a mejorar la precisión del forecast y reducir ineficiencias operativas dentro de la industria textil y retail. Es importante señalar que los estudios revisados emplean métricas de desempeño distintas entre sí (reducciones porcentuales de costos, MAPE, RMSE, entre otras), por lo que la comparación entre ellos se realiza en términos de tendencia general y no de equivalencia estadística exacta. Aun con esta heterogeneidad metodológica, la consistencia con la que los distintos estudios (en contextos, países y niveles de madurez tecnológica muy diferentes) reportan mejoras al migrar de métodos empíricos a métodos estadísticos refuerza la solidez de la evidencia disponible.

Estos antecedentes proporcionan sustento teórico y aplicado para el desarrollo de la presente investigación.

3. Metodología

El presente estudio se desarrolla bajo un enfoque de revisión documental y análisis comparativo aplicado al forecasting de demanda en la industria textil. La metodología se orienta a identificar las principales variables, métricas y métodos utilizados en la literatura reciente, así como evaluar su impacto sobre la precisión del forecast y la gestión de inventarios en entornos caracterizados por alta incertidumbre y volatilidad.

Asimismo, se consideran distintos enfoques metodológicos y escenarios de análisis reportados en investigaciones nacionales e internacionales, con el objetivo de sistematizar hallazgos relevantes y establecer criterios de evaluación aplicables a procesos de planificación de demanda dentro de la cadena de suministro textil.

3.1. Tipo de investigación (Teórica, documental, exploratoria y comparativa)

El presente estudio se define como una investigación de tipo documental, desarrollada bajo un enfoque teórico, exploratorio y comparativo. La metodología se sustenta en el análisis de información secundaria proveniente de investigaciones previas relacionadas con forecasting de demanda, métricas de precisión y planificación dentro de la industria textil y retail.

El objetivo de este diseño metodológico consiste en analizar y comparar distintos métodos de forecasting y métricas de precisión aplicadas en entornos de alta volatilidad. Asimismo, el enfoque exploratorio permite identificar variables críticas reportadas en la literatura que afectan la exactitud del forecast, mientras que el enfoque comparativo facilita evaluar el desempeño relativo de modelos estadísticos tradicionales y metodologías más recientes basadas en Machine Learning.

3.2. Estrategia de revisión de literatura

Para el desarrollo de la investigación se implementó una estrategia de búsqueda sistemática en bases de datos académicas como Scopus, Web of Science y Google Académico. Las palabras clave utilizadas incluyeron términos en español e inglés relacionados con forecasting, supply chain, precisión del forecast, industria textil y métodos estadísticos de pronóstico.

Los criterios de inclusión priorizaron investigaciones publicadas entre 2015 y 2025 que presentaran resultados cuantitativos, comparaciones entre metodologías de forecasting y aplicaciones relacionadas con industria textil, retail o planificación de demanda. Asimismo, se consideraron benchmarks nacionales e internacionales con el objetivo de contextualizar los hallazgos dentro de entornos comparables a la realidad del sector textil argentino.

El proceso de sistematización consistió en clasificar los estudios según los métodos de forecasting utilizados, horizonte de análisis y métricas de precisión reportadas, tales como MAPE, WAPE y RMSE. Posteriormente, se realizó un análisis comparativo orientado a identificar tendencias, mejoras de precisión y principales limitaciones reportadas en la literatura revisada.

3.3. Variables de análisis

Para la revisión y comparación de estudios relacionados con forecasting en la industria textil, se definieron distintas variables de análisis orientadas a identificar similitudes, diferencias y patrones metodológicos entre las investigaciones revisadas. Entre las principales variables consideradas se encuentran el nivel de agregación de la demanda (SKU, categoría o familia de productos), el horizonte de forecast utilizado (corto, mediano o largo plazo), los métodos de pronóstico aplicados y las métricas de precisión reportadas por cada estudio.

Asimismo, se analizaron variables asociadas al contexto operativo de las investigaciones, tales como tipo de industria, presencia de entornos volátiles, utilización de herramientas estadísticas o algoritmos de Machine Learning y aplicación de escenarios de simulación dentro de procesos de planificación de demanda.

La selección de estas variables permitió estructurar un análisis comparativo homogéneo entre estudios nacionales e internacionales, facilitando la identificación de tendencias y prácticas relevantes dentro del forecasting aplicado a la industria textil.

3.4. Procedimiento de análisis

Se desarrolló mediante una revisión, clasificación y sistematización de los estudios seleccionados en función de las variables definidas previamente. Posteriormente, se realizó una comparación de metodologías, métricas y resultados reportados en las distintas investigaciones revisadas.

Asimismo, se identificaron patrones comunes relacionados con mejoras de precisión, reducción de errores de forecast y aplicación de herramientas analíticas dentro de procesos de planificación de demanda y gestión de inventarios.

3.4.1. Clasificación de métodos, sistematización de resultados, comparación de métricas

Los estudios analizados fueron clasificados según el tipo de metodología de forecasting utilizada, diferenciando principalmente modelos estadísticos tradicionales, métodos de suavización, modelos ARIMA y enfoques basados en Machine Learning.

Posteriormente, los resultados fueron sistematizados considerando las métricas de precisión reportadas en cada investigación, tales como MAPE, WAPE, MAE y RMSE, permitiendo comparar el desempeño relativo de los distintos enfoques aplicados.

Finalmente, se realizó un análisis comparativo orientado a identificar tendencias recurrentes, ventajas operativas y principales limitaciones reportadas en la literatura respecto a la aplicación de modelos de forecasting en entornos textiles caracterizados por alta variabilidad de demanda e incertidumbre operativa.

3.4.2. Metodologías empleadas en los estudios analizados

Con el propósito de complementar la información presentada en la Tabla 6. Resumen de estudios previos en forecasting textil y retail, a continuación se describen las principales metodologías de pronóstico empleadas en los estudios analizados. Esta descripción permite comprender las características de cada enfoque, su aplicación dentro de los casos revisados y su contribución al análisis comparativo desarrollado en la presente investigación. Si bien algunas investigaciones utilizan un único método de pronóstico, otras combinan herramientas estadísticas, técnicas de simulación o modelos de apoyo a la toma de decisiones, evidenciando la diversidad metodológica existente en la literatura sobre forecasting de demanda.

- **Simulación Monte Carlo:** La simulación Monte Carlo genera múltiples escenarios posibles a partir de distribuciones de probabilidad para evaluar el comportamiento de la demanda bajo incertidumbre (Ramírez Agudelo, 2013). Su objetivo es fortalecer la toma de decisiones mediante el análisis de distintos escenarios de planificación. Altamirano y Caruso (2015) la emplearon para mejorar el forecast en una PyME textil con información histórica limitada (Nahmias, 2015).

- **Proceso Analítico Jerárquico (PAJ/AHP):** El PAJ es una metodología multicriterio que permite incorporar variables cuantitativas y cualitativas dentro del proceso de decisión. Su objetivo es complementar el pronóstico estadístico mediante el juicio de expertos. Altamirano y Caruso (2015) la utilizaron para incorporar variables como el PBI y la inflación en el forecasting.
- **Suavización Exponencial:** La suavización exponencial es una técnica de series de tiempo que asigna mayor peso a las observaciones recientes para estimar la demanda futura (NAHMIAS). Resulta adecuada para series con patrones estables o estacionales. Fue aplicada por Valera García (2022) y Huaca León (2018) para optimizar inventarios y reducir quiebres de stock.
- **Análisis ABC:** El análisis ABC clasifica los productos según su importancia económica, priorizando aquellos con mayor impacto sobre las ventas o el inventario. Su objetivo es focalizar los esfuerzos de planificación en los artículos estratégicos. Valera García (2022) y Altamirano y Caruso (2015) emplearon esta metodología para segmentar el portafolio antes del forecasting.
- **Machine Learning:** El Machine Learning utiliza algoritmos capaces de identificar patrones complejos y mejorar la precisión de los pronósticos en demandas de alta variabilidad (VIVAS). En algunos estudios se complementó con Google Trends como variable externa para captar cambios en el interés del consumidor. Medina Samaniego (2021) y Vivas Arequipa (2025) obtuvieron mejoras en la precisión mediante este enfoque.
- **Juicio experto y Quick Response:** El juicio experto incorpora información cualitativa que no se encuentra en las series históricas, mientras que Quick Response busca adaptar rápidamente la producción al comportamiento real de la demanda (BOADA). Ambos enfoques son apropiados para productos con ciclos de vida cortos. Fisher et al. (1994) y Altamirano y Caruso (2015) los utilizaron en la planificación de la demanda textil.
- **Modelos ARIMA / SARIMA:** Los modelos ARIMA y SARIMA analizan el comportamiento histórico de una serie de tiempo para proyectar la demanda considerando tendencia y estacionalidad. Son apropiados para demandas con

patrones recurrentes. Altamirano y Caruso (2015) y Vivas Arequipa (2025) los aplicaron en sus estudios de pronóstico.

- **Modelos Bayesianos y Regresión Múltiple:** Los modelos bayesianos actualizan el pronóstico conforme se incorpora nueva información, mientras que la regresión múltiple explica la demanda mediante variables independientes. Ambos enfoques buscan mejorar la capacidad predictiva incorporando información adicional al historial de ventas. Ramírez Agudelo (2013) y Boada (2017) utilizaron estas metodologías en sus investigaciones.

3.5. Análisis de escenarios

Como parte del análisis metodológico, se consideraron investigaciones que incorporan escenarios de simulación para evaluar el comportamiento del forecast bajo distintos niveles de incertidumbre. Este enfoque permite analizar la sensibilidad de los modelos frente a variaciones en la demanda, cambios macroeconómicos y fluctuaciones operativas reportadas dentro de la industria textil y retail; además de facilitar la identificación de riesgos asociados a quiebres de stock, sobre-inventario y desviaciones significativas en los niveles de planificación. Esto finalmente contribuye a evaluar la capacidad de respuesta de los modelos utilizados en entornos de alta volatilidad.

3.5.1. Consideración de estudios que evalúen entornos base, optimistas y pesimistas

Dentro de la revisión realizada, se priorizaron estudios que incorporan escenarios base, optimistas y pesimistas como parte de sus procesos de análisis y validación de forecasting.

El escenario base corresponde a condiciones normales de comportamiento de demanda derivadas de patrones históricos, mientras que los escenarios optimistas y pesimistas consideran posibles incrementos o disminuciones significativas asociados a promociones, cambios de consumo, inflación, estacionalidad o interrupciones operativas.

La inclusión de estos enfoques permitió evaluar la robustez de los modelos analizados y comparar su desempeño frente a distintos niveles de incertidumbre dentro de la cadena de suministro.

3.6. Criterios de evaluación (interpretación de mejoras en MAPE/WAPE y robustez de modelos en entornos VUCA)

La evaluación comparativa de los estudios revisados se realizó considerando principalmente las métricas de precisión reportadas por cada investigación, especialmente indicadores como MAPE, WAPE, MAE y RMSE.

Asimismo, se analizaron las mejoras obtenidas en términos de reducción de error, disminución de quiebres de stock, reducción de sobre-inventario y capacidad de adaptación de los modelos frente a entornos caracterizados por volatilidad e incertidumbre.

Adicionalmente, se consideró la robustez metodológica de los modelos implementados, entendida como su capacidad para mantener niveles aceptables de precisión bajo distintos escenarios operativos y contextos VUCA. Este criterio permitió identificar enfoques con mayor estabilidad y aplicabilidad dentro de procesos de planificación de demanda en la industria textil.

4. Análisis y Discusión de Resultados de la Literatura

Con el propósito de evaluar la evidencia disponible sobre el impacto de los métodos estadísticos en la precisión del pronóstico de demanda, se realizó una revisión y sistematización de estudios académicos y aplicaciones empresariales relacionadas con forecasting, gestión de inventarios y planificación de la demanda. La literatura seleccionada incluye investigaciones desarrolladas principalmente en la industria textil, complementadas con estudios pertenecientes a sectores comparables (como consumo masivo) que presentan características similares en términos de variabilidad de la demanda, estacionalidad, multiplicidad de SKU y necesidad de coordinación entre las áreas de la cadena de suministro.

El análisis se orienta a identificar las principales problemáticas abordadas por la literatura, los métodos de pronóstico utilizados, las métricas empleadas para evaluar el desempeño de los modelos y los resultados obtenidos en términos de precisión, eficiencia operativa e impacto que tienen los métodos usados en los resultados. Asimismo, se examinan los factores que influyen en el desempeño de los modelos de forecasting y las implicancias que estos hallazgos pueden tener para la industria textil argentina, caracterizada por operar en entornos de elevada incertidumbre, inflación y cambios frecuentes en los patrones de consumo.

A partir de la evidencia recopilada se busca contrastar la hipótesis planteada en esta investigación, según la cual la aplicación de métodos estadísticos permite mejorar significativamente la precisión del forecast respecto de enfoques empíricos o basados exclusivamente en juicio experto.

4.1. Caracterización de los estudios analizados

Con el fin de contextualizar y sintetizar la evidencia recopilada, se realizó una caracterización de los estudios seleccionados considerando el país de origen, el sector económico analizado, el tipo de investigación desarrollada y el objetivo principal perseguido por cada autor. Esta caracterización permite comprender el alcance de la literatura revisada y evaluar la pertinencia de los hallazgos para el contexto de la industria textil.

Tabla 7. Estudios pertenecientes al sector textil

Autor	Año	País	Subsector textil	Tipo de estudio
Altamirano & Caruso	2015	Argentina	Confección (PyME)	Aplicado / Investigación operativa
Valera García	2022	Perú	Indumentaria deportiva	Aplicativo / Cuasiexperimental
Huaca León	2018	Colombia	Línea de tela cortina	Estudio de caso
Medina Samaniego	2021	Ecuador	Confección (MiPymes)	Aplicado / Minería de datos
Jebbor et al.	2024	Marruecos	Manufactura de prendas	Aplicativo / Machine Learning
Arrieta et al.	2017	Colombia	Confección	Desarrollo tecnológico / ERP
Prapti Jain	2024	India	Tejido y materiales	Aplicación de Inteligencia Artificial

Fuente: Elaboración propia a partir de literatura revisada

Tabla 8. Estudios de sectores comparables incluidos en la revisión

Autor	Año	País	Industria	Justificación de inclusión
-------	-----	------	-----------	----------------------------

Vivas Arequipa	2025	Ecuador	Consumo masivo (Lácteos)	Demanda estacional y múltiples SKU
Boada	2017	Venezuela	Consumo masivo (Cosméticos)	Ciclos de vida cortos y promociones
Ramírez Agudelo	2013	Colombia	Manufactura	Series con pocos datos históricos
Valencia- Cárdenas	2015	Colombia	Multisectorial	Inventarios con demanda dinámica
Petropoulos et al.	2022	Internacional	General	Benchmark internacional de forecasting
Nahmias	2007	Internacional	General	Fundamentos teóricos de forecasting e inventarios

Fuente: Elaboración propia a partir de literatura revisada

La revisión comprendió un total de trece estudios, de los cuales siete pertenecen directamente a la industria textil y seis corresponden a sectores comparables. La predominancia de investigaciones textiles resulta consistente con el objetivo de la presente investigación, permitiendo analizar problemáticas y metodologías asociadas a contextos caracterizados por alta estacionalidad, ciclos de vida cortos de producto y elevada complejidad en la gestión de inventarios.

Los estudios textiles abarcan diversos contextos geográficos, incluyendo Argentina, Perú, Colombia, Ecuador, Marruecos e India, lo que aporta una visión amplia sobre las dificultades que enfrentan las organizaciones del sector en materia de planificación de la demanda. A pesar de las diferencias entre mercados, los trabajos coinciden en señalar desafíos comunes relacionados con la volatilidad de la demanda, la falta de precisión en los pronósticos y la necesidad de mejorar los procesos de planificación.

Por otra parte, los estudios pertenecientes a sectores comparables fueron incorporados debido a que enfrentan problemáticas similares a las observadas en la industria textil. Sectores como consumo masivo, manufactura y retail presentan desafíos asociados a la gestión de múltiples SKU, estacionalidad, incertidumbre de la demanda y necesidad de optimizar inventarios para lograr una pronta respuesta por parte de las empresas al mercado. En consecuencia, sus resultados constituyen una fuente complementaria de evidencia para evaluar la efectividad de los métodos estadísticos de pronóstico.

La Tabla 15 en la sección de anexos muestra la extracción documental consolidada con el fin de facilitar el análisis comparativo de los estudios seleccionados. Se busco relacionar las problemáticas abordadas, los métodos de pronóstico aplicados, las métricas de evaluación empleadas y los principales resultados obtenidos en cada investigación. Esta herramienta permitió homogeneizar la información proveniente de diferentes contextos y constituye la base para el desarrollo de los apartados siguientes.

4.2. Problemáticas identificadas en la literatura

La revisión de la literatura permitió identificar un conjunto de problemáticas recurrentes que afectan los procesos de planificación de la demanda y gestión de inventarios en la industria textil y sectores comparables. Si bien cada estudio fue desarrollado en contextos organizacionales distintos, se observaron patrones comunes relacionados con la baja precisión de los pronósticos, las consecuencias operativas derivadas de errores de planificación, las limitaciones metodológicas de los enfoques utilizados (métodos empíricos obsoletos) y la complejidad propia de entornos caracterizados por alta incertidumbre y variabilidad de la demanda.

Con el propósito de facilitar el análisis, las problemáticas identificadas fueron agrupadas en cuatro categorías principales: problemas relacionados con la precisión del forecast, problemas operativos asociados, problemas metodológicos y factores vinculados a la complejidad del entorno.

4.2.1. *Problemas relacionados con la precisión del forecast*

A partir de los estudios desarrollados por Altamirano y Caruso (2015), Valera García (2022), Huaca León (2018), Medina Samaniego (2021) y Vivas Arequipa (2025), es posible identificar que una de las problemáticas más recurrentes en la literatura corresponde a la baja precisión de los pronósticos de demanda. Si bien los contextos analizados presentan diferencias en

términos de tamaño empresarial, ubicación geográfica y características del mercado, los autores coinciden en señalar que la incapacidad para anticipar adecuadamente el comportamiento futuro de la demanda constituye una de las principales limitaciones para la planificación eficiente de las operaciones.

Los errores identificados afectan la capacidad de las organizaciones para tomar decisiones oportunas relacionadas con abastecimiento, producción, inventarios y distribución. En este sentido, Valera García (2022) y Huaca León (2018) señalan que las diferencias entre la demanda estimada y la demanda real generan incertidumbre en la planificación y dificultan la asignación eficiente de recursos. Asimismo, Nahmias (2015) destaca que el error de pronóstico constituye uno de los principales desafíos para la gestión de inventarios, debido a que condiciona la disponibilidad futura de productos y el nivel de servicio ofrecido a los clientes.

En el caso específico de la industria textil y tomando en cuenta las características propias del sector, la problemática adquiere una mayor relevancia. Altamirano y Caruso (2015) identifican que la estacionalidad y la limitada disponibilidad de datos históricos representan obstáculos significativos para la generación de pronósticos confiables en pequeñas y medianas empresas. De manera similar, Medina Samaniego (2021) evidencia que la volatilidad del mercado y los cambios en los patrones de consumo afectan negativamente la capacidad predictiva de los modelos tradicionales. Por su parte, Jebbor et al. (2024) y IJSRET (2024) resaltan que la creciente complejidad de las cadenas de suministro textiles exige herramientas capaces de adaptarse a escenarios dinámicos y altamente variables.

Otro aspecto recurrente identificado en la literatura es la necesidad de medir objetivamente la precisión de los modelos utilizados. Valera García (2022), Medina Samaniego (2021), Petropoulos et al. (2022) y Nahmias (2007) coinciden en que la utilización de métricas cuantitativas permite evaluar el desempeño de los pronósticos y comparar distintos métodos de estimación bajo criterios homogéneos. Entre los indicadores más utilizados destacan el Mean Absolute Percentage Error (MAPE), Mean Absolute Deviation (MAD), Root Mean Squared Error (RMSE), Mean Squared Error (MSE) y otras métricas asociadas a la medición del error. La adopción de estos indicadores representa un avance respecto a enfoques basados exclusivamente en experiencia o juicio experto, ya que proporciona herramientas objetivas para la selección y mejora continua de los modelos de forecasting.

La importancia de esta problemática se encuentra directamente vinculada con el objetivo principal de la presente investigación, el cual consiste en analizar el impacto de los métodos

estadísticos en la precisión del pronóstico de demanda dentro de la industria textil. La recurrencia de errores de forecast observada en los estudios revisados pone de manifiesto la necesidad de evaluar alternativas metodológicas que permitan reducir dichas desviaciones y mejorar la confiabilidad de los procesos de planificación.

En consecuencia, la baja precisión del forecast puede considerarse como el punto de partida común de gran parte de la literatura analizada. La evidencia recopilada muestra que la dificultad para estimar adecuadamente la demanda futura continúa siendo una preocupación transversal en distintos sectores productivos, particularmente en aquellos caracterizados por alta estacionalidad, ciclos de vida cortos y elevada incertidumbre. Los hallazgos identificados constituyen un primer indicio favorable para la hipótesis planteada en esta investigación, según la cual la aplicación de métodos estadísticos contribuye a mejorar la precisión de los pronósticos respecto a enfoques empíricos o basados exclusivamente en juicio experto. No obstante, la validación de dicha hipótesis requiere analizar posteriormente los métodos utilizados y los resultados cuantitativos reportados por los estudios revisados, puntos que serán desarrollados en los apartados siguientes.

Tabla 9. Problemas relacionados con la precisión del forecast identificados en la literatura

Problema de precisión	Estudios que lo reportan
Baja precisión del forecast	Altamirano y Caruso (2015), Valera García (2022), Huaca León (2018), Medina Samaniego (2021), Vivas Arequipa (2025)
Alto error de pronóstico	Altamirano y Caruso (2015), Valera García (2022), Medina Samaniego (2021)
Alta variabilidad entre demanda real y proyectada	Huaca León (2018), Medina Samaniego (2021), Vivas Arequipa (2025)
Baja confiabilidad de las proyecciones	Altamirano y Caruso (2015), Valera García (2022)
Dificultad para anticipar cambios de demanda	Medina Samaniego (2021), Jebbor et al. (2024), Vivas Arequipa (2025)

Fuente: Elaboración propia

4.2.2. Problemas operativos asociados

Además de los problemas relacionados con la precisión de los pronósticos, la literatura revisada evidencia que los errores de forecasting generan consecuencias operativas que afectan directamente el desempeño de las organizaciones. Los estudios analizados muestran que las desviaciones entre la demanda proyectada y la demanda real repercuten en la gestión

de inventarios, el abastecimiento, la producción y el nivel de servicio al cliente. En consecuencia, diversas investigaciones han centrado sus esfuerzos en identificar y reducir los impactos operativos derivados de una planificación deficiente de la demanda.

A continuación, se presenta los principales problemas operativos identificados, así como las principales consecuencias.

Tabla 10. Problemas operativos asociados identificados en la literatura

Problema operativo	Consecuencia observada	Estudios que lo reportan
Sobrestock y exceso de inventario	Incremento de costos de almacenamiento, inmovilización de capital de trabajo, mayor riesgo de obsolescencia y reducción de liquidez para nuevas inversiones.	Valera García (2022); Huaca León (2018); Arrieta et al. (2017); Nahmias (2007)
Quiebres de stock	Pérdida de ventas, incumplimiento de pedidos, desequilibrio en producción, cuellos de botella, disminución del nivel de servicio y afectación de la satisfacción del cliente.	Valera García (2022); Huaca León (2018); Altamirano y Caruso (2015); Nahmias (2007)
Desabastecimiento	Incapacidad para responder oportunamente a la demanda del mercado, afectando la continuidad operativa y la competitividad empresarial.	Vivas Arequipa (2025); Huaca León (2018)
Costos elevados de almacenamiento	Incremento de gastos logísticos y reducción de la rentabilidad debido a una planificación ineficiente de inventarios.	Valera García (2022); Arrieta et al. (2017)
Ineficiencias en la planificación de compras y producción	Asignación inadecuada de recursos, utilización ineficiente de capacidad productiva y mayores costos operativos, falta de flexibilidad en la respuesta a picos de demanda.	Arrieta et al. (2017); Valera García (2022)
Bajo nivel de servicio al cliente	Menor disponibilidad de productos y deterioro de la capacidad de respuesta frente a las necesidades del mercado.	Valencia-Cárdenas (2015); Nahmias (2007)

Fuente: Elaboración propia

Se puede observar que las consecuencias operativas derivadas de errores de pronóstico trascienden el ámbito estadístico y afectan directamente los resultados empresariales. Tanto en la industria textil como en sectores comparables, los problemas más recurrentes corresponden a excesos de inventario, quiebres de stock y dificultades para mantener niveles adecuados de servicio al cliente. Estos efectos reflejan la estrecha relación existente entre la calidad de los pronósticos y el desempeño de las operaciones.

Desde la perspectiva de la presente investigación, estos hallazgos refuerzan la importancia de mejorar la precisión del forecast como mecanismo para optimizar la planificación de la demanda y reducir ineficiencias operativas. Por otro lado, evidencian que los beneficios potenciales de los métodos estadísticos no se limitan únicamente a la reducción del error de pronóstico, sino que pueden traducirse en mejoras concretas en indicadores transversales asociados a inventarios, costos y nivel de servicio, aspectos especialmente relevantes para la industria textil.

4.2.3. Problemas metodológicos

Además de las dificultades asociadas a la precisión de los pronósticos y sus consecuencias operativas, la literatura revisada identifica diversas limitaciones metodológicas que afectan la calidad de los procesos de planificación de la demanda. Estas limitaciones se encuentran relacionadas principalmente con la dependencia de métodos empíricos, el uso de herramientas manuales y la ausencia de modelos analíticos avanzados capaces de capturar y predecir adecuadamente el comportamiento de la demanda. Diversos autores sostienen que estas prácticas restringen la capacidad de las organizaciones para generar pronósticos confiables y responder eficientemente a entornos cada vez más complejos y dinámicos. La Tabla 11 presenta los principales problemas metodológicos identificados en la literatura revisada, así como las consecuencias observadas y los estudios que reportan cada situación.

Tabla 11. Problemas metodológicos identificados en la literatura

Problema metodológico	Consecuencia observada	Estudios que lo reportan
Dependencia del juicio experto	Mayor subjetividad y variabilidad en las decisiones de planificación, ausencia de registro de atípicos, dificultad de estandarización de procesos.	Altamirano y Caruso (2015); Valera García (2022)

Concentración de conocimiento en una persona	Riesgo de pérdida de conocimiento organizacional, dificultades para la continuidad operativa y ausencia de procesos formalizados que permitan asegurar la transferencia de información.	Altamirano y Caruso (2015); Arrieta et al. (2017)
Uso de herramientas manuales (Excel)	Limitaciones para procesar grandes volúmenes de información, actualizar pronósticos oportunamente y gestionar múltiples SKU de forma eficiente.	Arrieta et al. (2017); Valera García (2022)
Ausencia de trazabilidad de eventos y decisiones de forecast	Dificultad para explicar desviaciones históricas, identificar eventos atípicos y comprender las razones detrás de ajustes realizados en los pronósticos.	Altamirano y Caruso (2015); Arrieta et al. (2017)
Ausencia de modelos estadísticos formales	Menor precisión en las proyecciones y dificultad para identificar patrones de demanda	Altamirano y Caruso (2015); Arrieta et al. (2017)
Falta de integración de información	Descoordinación entre áreas y dificultades para la toma de decisiones basada en información consolidada y colocación de inputs de información complementaria.	Arrieta et al. (2017); Vivas Arequipa (2025)
Escasa automatización del forecasting	Mayor dependencia de procesos manuales, incremento de tiempo de análisis y aumento del riesgo de errores operativos.	Arrieta et al. (2017); Boada (2017)

Fuente: Elaboración propia.

La evidencia recopilada permite observar que gran parte de las limitaciones metodológicas identificadas en la literatura se relacionan con la gestión y utilización del conocimiento dentro de las organizaciones. Más allá de las herramientas empleadas, varios estudios muestran que los procesos de planificación suelen depender de conocimientos tácitos acumulados por determinados colaboradores, dificultando la transferencia de información y la continuidad operativa cuando dichos conocimientos no se encuentran formalmente documentados.

Asimismo, la ausencia de registros estructurados sobre promociones, lanzamientos, eventos extraordinarios o decisiones de ajuste realizadas durante el proceso de forecasting limita la trazabilidad de la información. Esta situación dificulta la interpretación de desviaciones históricas de la demanda y reduce la capacidad de aprendizaje organizacional, ya que resulta complejo comprender las causas que originaron determinados comportamientos o evaluar posteriormente la efectividad de las decisiones adoptadas; además del hecho de tener una gran posibilidad de sub o sobre estimar y que concluya en un mal manejo de stock.

Desde la perspectiva de la presente investigación, estas limitaciones adquieren especial relevancia en procesos integrados de planificación como el S&OP, donde la coordinación entre áreas requiere información consistente, criterios homogéneos y mecanismos que permitan justificar las decisiones tomadas. Por ello, la adopción de metodologías estructuradas, estandarizadas y herramientas analíticas contribuye no solo a mejorar la precisión de los pronósticos, sino también a fortalecer la gobernanza del proceso de planificación y la calidad de la toma de decisiones.

4.2.4. Complejidad del entorno

Además de los problemas operativos y metodológicos, la literatura revisada destaca una serie de factores externos e internos que incrementan la complejidad de los procesos de pronóstico de demanda. Estas condiciones generan incertidumbre y dificultan la identificación de patrones estables de comportamiento, especialmente en sectores caracterizados por alta variabilidad y cambios frecuentes en las preferencias de los consumidores.

La Tabla 12 presenta los principales factores de complejidad identificados en los estudios analizados:

Tabla 12. Factores de complejidad del entorno identificados en la literatura

Factor de complejidad	Impacto observado	Estudios que lo reportan
Estacionalidad	Variaciones recurrentes de la demanda que dificultan la estimación de volúmenes futuros.	Altamirano y Caruso (2015); Huaca León (2018); Valera García (2022)
Tendencias de moda	Cambios rápidos en las preferencias del consumidor y reducción del ciclo de vida de los productos.	Altamirano y Caruso (2015); Medina Samaniego (2021)
Volatilidad de la demanda	Mayor dificultad para identificar patrones consistentes de comportamiento.	Medina Samaniego (2021); Jebbor et al. (2024)
Entornos VUCA e incertidumbre económica	Incremento de la variabilidad y reducción de la capacidad predictiva de los modelos tradicionales.	Medina Samaniego (2021); Jebbor et al. (2024)

Alta cantidad de SKU	Mayor complejidad para gestionar y pronosticar múltiples referencias simultáneamente.	Valera García (2022); Arrieta et al. (2017)
Variaciones del poder adquisitivo	Cambios en la capacidad de compra que modifican el volumen y la composición de la demanda	Braun & Llach (2010); Gonzales Perez (2020)
Apertura comercial e importaciones	Mayor presión competitiva y cambios en las estrategias de abastecimiento y precios.	CEPAL; CAME
Dependencia de materias primas importadas	Mayor exposición al tipo de cambio y a variaciones de costos.	CEPAL; CAME

Fuente: Elaboración propia

La evidencia presentada muestra que las características propias del entorno adquieren gran importancia e influencia para pronosticar la demanda. En particular, la industria textil se encuentra expuesta a factores como la estacionalidad, los cambios en las tendencias de consumo y la alta diversidad de productos, elementos que incrementan la dificultad de los procesos de planificación; en otras palabras, esta industria enfrenta una complejidad adicional derivada de factores macroeconómicos que trascienden las características propias del sector. La evolución del poder adquisitivo de los consumidores, la apertura comercial, la competencia de productos importados y la dependencia de materias primas del exterior modifican constantemente las condiciones del mercado, afectando el comportamiento de la demanda y aumentando la incertidumbre de los procesos de planificación.

Estos hallazgos resultan relevantes para la presente investigación, ya que permiten comprender que la precisión del forecast depende tanto de la calidad de los métodos utilizados como del contexto en el que estos son aplicados. Por ello, la capacidad de los modelos estadísticos para adaptarse a escenarios de incertidumbre constituye un aspecto clave que será analizado en los apartados posteriores.

4.3. Comparación de métodos de pronóstico identificados

Una vez identificadas las principales problemáticas presentes en la literatura, resulta necesario analizar los métodos de pronóstico utilizados para abordarlas. Los estudios revisados evidencian una evolución progresiva desde enfoques predominantemente empíricos hacia metodologías cuantitativas basadas en técnicas estadísticas y, más recientemente, en algoritmos de aprendizaje automático.

Esta transición responde a la necesidad de mejorar la precisión de los pronósticos y reducir las limitaciones asociadas a procesos de planificación dependientes exclusivamente de la experiencia individual. En consecuencia, los autores analizados emplean diferentes enfoques metodológicos, cuya complejidad y capacidad analítica varían en función de la disponibilidad de datos, los objetivos de la investigación y las características de la demanda estudiada.

4.3.1. Métodos empíricos

Los métodos empíricos se caracterizan por basar las decisiones de pronóstico principalmente en la experiencia, conocimiento y criterio de los responsables de planificación. Este enfoque continúa siendo frecuente en organizaciones con escasa disponibilidad de información histórica o con procesos de forecasting poco estructurados.

Sin embargo, diversos estudios identifican limitaciones asociadas a este tipo de metodologías, particularmente en contextos donde existe una alta cantidad de productos, elevada volatilidad de la demanda o fuerte influencia de factores estacionales. La subjetividad inherente a estos métodos dificulta la estandarización de los procesos y limita la posibilidad de evaluar objetivamente la calidad de las proyecciones realizadas evitando la mejora continua de la compañía. Los métodos empíricos mas comunes se detallan en la Tabla 13:

Tabla 13. Metodos empíricos mas comunes identificados en la literatura.

Método	Descripción	Estudios
Juicio experto	Pronóstico basado en experiencia y conocimiento del planificador	Altamirano y Caruso (2015); Valera García (2022)
Ajustes manuales	Modificaciones realizadas sobre pronósticos sin criterios cuantitativos formalizados y muchas veces sin registro del porqué.	Valera García (2022); Arrieta et al. (2017)
Consenso entre áreas	Proyecciones elaboradas mediante reuniones y acuerdos entre distintas áreas funcionales sin dejar minutas que dificultan posteriormente la identificación de atípicos para su tratamiento correspondiente en la planificación.	Arrieta et al. (2017)

Fuente: Elaboracion propia

4.3.2. Métodos estadísticos tradicionales

Los métodos estadísticos tradicionales constituyen el grupo de técnicas más ampliamente utilizado en la literatura revisada para mejorar la precisión de los pronósticos de demanda. A diferencia de los enfoques empíricos, estos métodos se apoyan en el análisis cuantitativo de datos históricos para identificar patrones de comportamiento y generar proyecciones futuras bajo criterios objetivos y reproducibles. Por lo tanto, el tratamiento a los datos base cobra vital importancia en esta parte; ya que, la calidad de la información utilizada influye directamente en la capacidad de los modelos para identificar patrones, tendencias y comportamientos estacionales de la demanda.

Diversos autores incorporan herramientas estadísticas con el propósito de reducir la subjetividad asociada al juicio experto y mejorar la capacidad predictiva de los procesos de planificación. Entre los métodos más frecuentes se encuentran los promedios móviles, la suavización exponencial, los modelos de Holt y Holt-Winters, los modelos ARIMA y SARIMA, así como enfoques bayesianos aplicados a series con información limitada. La Tabla 14 contiene un resumen de los métodos utilizados en los estudios analizados. Igualmente, en el capítulo dos correspondiente a marco teórico se profundiza en cada uno de estos modelos.

Tabla 14. Modelos estadísticos más comunes usados en los estudios analizados

Método	Características principales	Estudios que lo utilizan
Promedios móviles	Utiliza observaciones históricas recientes para suavizar fluctuaciones y estimar valores futuros.	Nahmias (2007)
Suavización exponencial simple	Asigna mayor peso a los datos más recientes para generar pronósticos de corto plazo.	Valera García (2022); Altamirano y Caruso (2015)
Suavización exponencial doble (Holt)	Incorpora tendencia en la serie de tiempo para mejorar la capacidad predictiva.	Huaca León (2018)
Holt-Winters	Considera simultáneamente nivel, tendencia y estacionalidad de la demanda.	Altamirano y Caruso (2015)
ARIMA	Modela relaciones temporales dentro de series históricas para generar pronósticos.	Vivas Arequipa (2025); Nahmias (2007)
SARIMA	Extensión de ARIMA que incorpora componentes estacionales.	Vivas Arequipa (2025); Altamirano y Caruso (2015)

Fuente: elaboración propia

4.3.3. Métodos avanzados y machine learning

El avance de la capacidad computacional y la creciente disponibilidad de datos han favorecido la incorporación de técnicas de Machine Learning en los procesos de forecasting. Estas metodologías representan una evolución de los enfoques cuantitativos tradicionales, permitiendo complementar el análisis histórico de la demanda mediante el procesamiento de grandes volúmenes de información y la incorporación de variables adicionales que pueden influir en el comportamiento del mercado.

La revisión de la literatura evidencia que el uso de Machine Learning se concentra principalmente en investigaciones recientes, donde se busca mejorar la capacidad predictiva de los modelos frente a escenarios caracterizados por alta incertidumbre, cambios rápidos en las preferencias de los consumidores y entornos de elevada complejidad. En particular, estudios como los de Medina Samaniego (2021), Jebbor et al. (2024), IJSRET (2024) y Vivas Arequipa (2025) incorporan herramientas analíticas avanzadas para fortalecer los procesos de planificación de la demanda y gestión de inventarios.

No obstante, la evidencia recopilada muestra que los métodos estadísticos tradicionales continúan siendo los más utilizados en la práctica empresarial y en gran parte de los estudios analizados. Esto se debe a que ofrecen un adecuado equilibrio entre precisión, facilidad de implementación e interpretación de resultados. Asimismo, la adopción de técnicas avanzadas de Machine Learning suele requerir mayores niveles de madurez analítica, integración de sistemas de información, disponibilidad de datos de calidad y capacidades tecnológicas especializadas, condiciones que todavía no se encuentran plenamente desarrolladas en muchas organizaciones. En este sentido, los métodos avanzados pueden considerarse una visión de evolución futura para los procesos de forecasting, representando un escenario hacia el cual las empresas podrían orientarse a medida que fortalezcan sus capacidades digitales y sus sistemas de planificación. Sin embargo, la literatura revisada sugiere que, en el contexto actual, la prioridad para muchas organizaciones continúa siendo la consolidación de procesos estandarizados, la mejora en la calidad de los datos y la implementación efectiva de métodos estadísticos tradicionales, los cuales constituyen la base necesaria para una futura incorporación de herramientas más sofisticadas de analítica y Machine Learning.

4.4. Variables y condiciones de análisis utilizadas en los estudios

Con el propósito de identificar las condiciones metodológicas bajo las cuales fueron desarrollados los estudios analizados, se examinó la presencia de las variables críticas definidas en el marco teórico, así como los niveles de agregación, horizontes de pronóstico y métricas de evaluación empleadas por los autores. La información detallada se presenta en

la Matriz Metodológica Maestra incluida en el Anexo 2, la cual permitió sistematizar y comparar las principales características de cada investigación. Para el análisis se consideraron prioritariamente los estudios aplicados pertenecientes a la industria textil, complementados por investigaciones desarrolladas en sectores comparables que presentan problemáticas similares de planificación de demanda e inventarios. Se excluyeron de este análisis las fuentes de carácter exclusivamente teórico o de revisión bibliográfica, debido a que no reportan condiciones metodológicas homogéneas que permitan efectuar comparaciones respecto al nivel de agregación, horizonte de forecast, métricas de evaluación y variables críticas consideradas.

4.4.1. Variables pronosticadas

Las variables críticas constituyen uno de los principales factores que determinan la complejidad de los procesos de forecasting en la industria textil. Tal como se desarrolló en el marco teórico, elementos como la estacionalidad, las tendencias de moda, los ciclos de vida cortos de los productos, stock disponible y la volatilidad del entorno influyen directamente sobre la precisión de los pronósticos y sobre la capacidad de las organizaciones para planificar sus operaciones de manera eficiente. Con el fin de evaluar la relevancia de dichas variables en la literatura analizada, se examinó su presencia dentro de los estudios aplicados seleccionados, cuyos resultados se resumen en la Tabla 16, Matriz Metodológica Comparativa presentada en la sección de anexos.

La estacionalidad emerge como la variable más recurrente dentro de los estudios revisados. Diversos autores la identifican como una de las principales fuentes de variabilidad de la demanda y, por lo tanto, como un factor determinante en la selección de los modelos de pronóstico. Altamirano y Caruso (2015) incorporan explícitamente componentes estacionales mediante modelos SARIMA y Holt-Winters, mientras que Kačmár y Lörinc (2023) centran su análisis en productos de moda con ciclos semestrales marcadamente estacionales. De forma similar, Vivas Arequipa (2025) emplea modelos SARIMA para capturar patrones periódicos presentes en la demanda de productos de consumo masivo. Estos hallazgos evidencian que la correcta identificación de patrones estacionales continúa siendo uno de los desafíos centrales para mejorar la precisión del forecast.

Otra variable ampliamente abordada corresponde a la segmentación de productos, especialmente mediante metodologías ABC por valor de consumo. Los estudios de Altamirano y Caruso (2015), Valera García (2022) y Huaca León (2018) utilizan esta clasificación para identificar aquellos productos que concentran la mayor participación en

ventas o consumo (Demanda anual $\times$ costo unitario), permitiendo focalizar los esfuerzos y recursos de planificación sobre los artículos de mayor impacto operativo y financiero. La literatura coincide en señalar que la segmentación facilita la asignación eficiente de recursos y contribuye a mejorar la gestión de inventarios en entornos caracterizados por una elevada cantidad de referencias.

Las tendencias de moda y los ciclos de vida cortos de los productos aparecen principalmente en los estudios específicos de la industria textil. En investigaciones como las de Medina Samaniego (2021) y Kačmár y Lörinc (2023), estas variables son consideradas elementos fundamentales para explicar la volatilidad de la demanda y las limitaciones de los modelos tradicionales basados únicamente en series históricas ya que entran a tallar por ejemplo productos exclusivos de lanzamiento. En particular, Medina Samaniego (2021) incorpora información proveniente de Google Trends como mecanismo para capturar cambios en los intereses de los consumidores, demostrando que las señales externas pueden complementar eficazmente los datos históricos cuando se trabaja con mercados dinámicos y altamente influenciados por tendencias.

Por otra parte, variables asociadas a la incertidumbre del entorno y a los contextos VUCA son abordadas mediante estrategias metodológicas cada vez más sofisticadas. Altamirano y Caruso (2015) recurren a simulaciones Monte Carlo (generación de escenarios posibles) para evaluar distintas posibilidades de comportamiento de la demanda, mientras que Boada (2017) y Ramírez Agudelo (2013) emplean enfoques bayesianos que permiten actualizar continuamente la información disponible y reducir el impacto de la incertidumbre sobre la toma de decisiones. De manera similar, Medina Samaniego (2021) utiliza algoritmos de Machine Learning capaces de identificar relaciones no lineales en entornos altamente variables. Asimismo, algunos estudios incorporan variables macroeconómicas como información complementaria para fortalecer el proceso de forecasting, considerando que cambios en el poder adquisitivo, el nivel de actividad económica o el comportamiento del consumo modifican significativamente la demanda esperada y permiten construir escenarios de planificación más representativos del entorno.

En conjunto, la evidencia analizada permite observar que las variables críticas definidas en el marco teórico no solo se encuentran presentes en la literatura especializada, sino que además condicionan la selección de los métodos utilizados, el diseño de los modelos y la calidad de los resultados obtenidos, siempre que se disponga de información histórica confiable. Adicionalmente, la literatura evidencia que la incorporación de variables macroeconómicas como el poder adquisitivo permite contextualizar el comportamiento de la

demanda y complementar la información proveniente de las series históricas, favoreciendo la construcción de escenarios de planificación y una mejor interpretación de los cambios observados en el mercado. En consecuencia, la precisión del forecast depende tanto de la metodología empleada como de la capacidad para integrar variables relevantes del entorno dentro del proceso de planificación.

4.4.2. Nivel de agregación

El nivel de agregación constituye una de las decisiones metodológicas más relevantes dentro de los procesos de forecasting, debido a que determina el grado de detalle con el que se realiza la estimación de la demanda. Los estudios analizados muestran una predominancia de modelos desarrollados a nivel de artículo, SKU, familia o categoría, dependiendo del objetivo perseguido por cada investigación.

En términos generales, los estudios orientados a la gestión operativa de inventarios y reposición tienden a trabajar con niveles más desagregados, como SKU o artículo, debido a la necesidad de planificar cantidades específicas de producto y tomar decisiones de abastecimiento con un alto nivel de detalle. Este enfoque resulta especialmente relevante en industrias como la textil, donde variables como el color, la talla o la presentación pueden generar comportamientos de demanda significativamente distintos entre productos pertenecientes a una misma familia. Por ejemplo, una remera puede presentar una demanda total estable a nivel artículo, pero exhibir diferencias importantes entre talles o colores cuando se analiza a nivel SKU. El análisis a este nivel no solo resulta relevante para las decisiones de abastecimiento y reposición, sino también para la gestión estratégica del portafolio de productos. La disponibilidad de información detallada permite evaluar periódicamente la contribución de cada referencia en términos de ventas, rotación y rentabilidad, facilitando la identificación de SKU que podrían ser discontinuados, consolidados o reemplazados por nuevas alternativas. De esta manera, el forecast a nivel desagregado se convierte en una herramienta complementaria para la optimización continua del portafolio y la asignación eficiente de recursos.

Por el contrario, las investigaciones orientadas a la planificación táctica o estratégica suelen utilizar niveles más agregados, como familias o categorías de productos. En estos casos, el objetivo no es definir cantidades exactas para cada referencia individual, sino estimar necesidades globales de producción, compras o capacidad operativa. La principal ventaja de este nivel de agregación es que las fluctuaciones individuales tienden a compensarse entre sí, reduciendo la variabilidad de la serie y permitiendo obtener pronósticos más estables y precisos. Por ejemplo, una empresa puede proyectar con mayor precisión la demanda total de la categoría "remeras" que la demanda específica de una remera blanca talla M.

La evidencia recopilada muestra la coexistencia de ambos enfoques dentro de la literatura analizada. Estudios como los de Valera García (2022), Huaca León (2018), Ramírez Agudelo (2013) y Kačmárý y Lörinc (2023) desarrollan sus modelos principalmente a nivel de artículo o SKU, debido a su orientación hacia la gestión de inventarios, reposición y planificación operativa. Por el contrario, investigaciones como las de Altamirano y Caruso (2015) y Vivas Arequipa (2025) incorporan niveles de agregación más amplios, trabajando con familias o categorías de productos para apoyar decisiones de carácter táctico y estratégico. Estos resultados sugieren que la selección del nivel de agregación no responde a una práctica estandarizada, sino a los objetivos específicos de planificación perseguidos por cada organización.

En resumen, la selección del nivel de agregación depende del propósito del forecast y de las necesidades de cada organización. Mientras los niveles desagregados favorecen la toma de decisiones operativas, los niveles agregados permiten una planificación más estable y orientada al mediano y largo plazo.

4.4.3. Horizonte de forecast

El horizonte de forecast constituye otro de los elementos metodológicos que varía significativamente entre los estudios analizados. La evidencia recopilada muestra una predominancia de horizontes de corto y mediano plazo, seleccionados en función de las necesidades operativas y estratégicas de cada organización. En términos generales, los horizontes más cortos son utilizados para actividades vinculadas a reposición, gestión de inventarios y abastecimiento buscando tener una mayor capacidad de reacción ante cambios del mercado; mientras que los horizontes más extensos se emplean para apoyar decisiones relacionadas con planificación de producción, capacidad y definición de estrategias comerciales cuando la prioridad del negocio es la programación de recursos, compras y producción con la anticipación necesaria para garantizar la disponibilidad de productos.

Los estudios de Valera García (2022) y Medina Samaniego (2021) utilizan horizontes mensuales y semanales respectivamente, debido a su enfoque en la gestión operativa de inventarios y la rápida respuesta a cambios en la demanda. De manera similar, Huaca León (2018) trabaja con un horizonte cercano a un año para optimizar la reposición de materiales y mejorar los niveles de servicio. Por otro lado, investigaciones como las de Altamirano y Caruso (2015), Ramírez Agudelo (2013) y Kačmárý y Lörinc (2023) emplean horizontes más amplios asociados a la planificación de colecciones, producción o evaluación de productos estacionales, donde resulta necesario evaluar decisiones con varios meses de anticipación.

4.4.4. Métricas utilizadas

Las métricas de evaluación constituyen un elemento fundamental dentro de los procesos de forecasting, ya que permiten medir objetivamente la precisión de los modelos y comparar el desempeño de distintas metodologías. Los estudios analizados muestran una amplia utilización de indicadores de error, siendo el MAPE (Mean Absolute Percentage Error) la métrica más frecuente debido a su facilidad de interpretación y a la posibilidad de comparar resultados entre productos con diferentes escalas de demanda.

En investigaciones como las de Altamirano y Caruso (2015), Medina Samaniego (2021), Vivas Arequipa (2025) y Ramírez Agudelo (2013), el MAPE es utilizado como principal indicador para evaluar la precisión de los pronósticos. Sin embargo, varios autores complementan su análisis con métricas como MAD, MAE, RMSE o MSE, con el objetivo de obtener una visión más completa del comportamiento de los errores y reducir las limitaciones asociadas al uso de un único indicador. Esta práctica resulta especialmente relevante en entornos caracterizados por alta volatilidad o presencia de valores atípicos, donde la interpretación del desempeño del forecast requiere un análisis más integral. Si bien el MAPE continúa siendo la métrica predominante debido a su facilidad de interpretación y comparación, la evidencia revisada sugiere que la evaluación de los pronósticos no debería limitarse únicamente a la precisión estadística. En este sentido, resulta igualmente importante considerar el impacto operativo y financiero de los errores, particularmente sobre la disponibilidad de producto, los niveles de servicio y las ventas potencialmente perdidas, permitiendo vincular el desempeño del forecast con los resultados del negocio.

La evidencia revisada sugiere que no existe una métrica única capaz de reflejar todos los aspectos del desempeño de un modelo de forecasting. En consecuencia, los estudios más robustos tienden a utilizar múltiples indicadores de manera complementaria, permitiendo evaluar tanto la magnitud del error como la estabilidad y consistencia de los resultados obtenidos.

4.5. Impacto de los métodos estadísticos en la precisión del forecast

La revisión de la literatura realizada permite identificar una tendencia consistente respecto al impacto positivo de los métodos estadísticos sobre la precisión del pronóstico de demanda. Los estudios analizados muestran que la incorporación de herramientas cuantitativas permite mejorar la calidad de las proyecciones en comparación con enfoques basados

exclusivamente en juicio experto o procedimientos empíricos debido a que facilitan la identificación temprana de valores atípicos, permiten reconocer con mayor precisión patrones de tendencia y estacionalidad, reducen la subjetividad en la interpretación de los datos y contribuyen a seleccionar el método de pronóstico más adecuado según las características de la serie analizada. Como resultado, las organizaciones pueden comprender mejor el comportamiento de la demanda y generar proyecciones más consistentes, objetivas y confiables para la toma de decisiones. En distintos contextos productivos y comerciales, la aplicación de metodologías estadísticas contribuyó a reducir errores de pronóstico, mejorar la capacidad de anticipación de la demanda y fortalecer la confiabilidad de la información utilizada para la toma de decisiones.

La evidencia recopilada también indica que los beneficios obtenidos no se limitan únicamente a mejoras en indicadores estadísticos como MAPE, RMSE o MAE. Diversos estudios reportan impactos operativos concretos asociados a una mayor precisión del forecast, tales como reducción de sobrestock, disminución de quiebres de stock, optimización de inventarios y mejoras en la coordinación entre las áreas de compras, producción y abastecimiento. En consecuencia, la precisión del pronóstico no debe interpretarse únicamente como una métrica estadística, sino como un factor que influye directamente en el desempeño de la cadena de suministro y en la eficiencia operativa de las organizaciones. Una mejora en la calidad del forecast permite optimizar la gestión de inventarios y coordinar de manera más eficiente los procesos de abastecimiento y producción. Asimismo, cuando estas proyecciones se integran dentro de procesos de Sales and Operations Planning (S&OP), las organizaciones adquieren una mayor capacidad para detectar cambios en los patrones de demanda, anticipar potenciales desvíos respecto al plan original y responder con mayor rapidez, eficacia y precisión a las variaciones del mercado. De esta manera, el forecasting deja de ser únicamente una herramienta de predicción para convertirse en un elemento clave de coordinación y soporte para la toma de decisiones estratégicas, tácticas y operativas de las compañías.

Asimismo, la literatura demuestra que los métodos estadísticos tradicionales continúan representando herramientas válidas y efectivas en numerosos contextos. Modelos como la suavización exponencial, Holt-Winters, ARIMA y SARIMA presentan resultados favorables cuando la demanda exhibe patrones relativamente estables o componentes estacionales claramente identificables. Esto resulta especialmente relevante para la industria textil, donde las colecciones, temporadas comerciales y ciclos de consumo generan comportamientos repetitivos que pueden ser capturados adecuadamente mediante este tipo de metodologías.

Uno de los principales hallazgos de la revisión es que no existe un método de forecasting universalmente superior. Si bien los estudios más recientes muestran que técnicas de Machine Learning como Random Forest o Support Vector Regression pueden ofrecer ventajas en entornos caracterizados por alta volatilidad, presencia de valores atípicos o relaciones no lineales, su desempeño continúa dependiendo de factores como la calidad de los datos, el horizonte de planificación y las características de la serie analizada. De manera similar, los modelos estacionales presentan mejores resultados en demandas con patrones recurrentes, mientras que los enfoques bayesianos resultan particularmente útiles cuando la información histórica es limitada. En consecuencia, la evidencia revisada sugiere que la efectividad del forecasting depende principalmente de la adecuada correspondencia entre las características de la demanda y la metodología seleccionada, más que del nivel de sofisticación del algoritmo utilizado.

Por lo tanto, a partir de la evidencia recopilada, puede afirmarse que la hipótesis planteada encuentra sustento en la literatura revisada. Los estudios analizados muestran que la adopción de métodos estadísticos mejora la precisión del forecast y aumenta la confiabilidad de la información utilizada en la planificación de la demanda. Sin embargo, la magnitud de estas mejoras depende de factores como la calidad de los datos, la estacionalidad, la variabilidad de la demanda y el contexto operativo, aspectos que serán analizados en la siguiente sección. En economías como la argentina, estos resultados adquieren una relevancia aún mayor debido a que el comportamiento de la demanda se encuentra influenciado por cambios frecuentes en el poder adquisitivo de los consumidores, la evolución del consumo interno, la apertura comercial y la dependencia de materias primas importadas, condiciones que incrementan la incertidumbre del proceso de planificación. En este contexto, los métodos estadísticos no solo permiten mejorar la precisión de los pronósticos, sino también proporcionar una base objetiva para construir escenarios de planificación y facilitar una toma de decisiones más flexible frente a cambios del entorno económico.

4.6. Factores críticos que afectan el desempeño de los modelos

Como se observó en las secciones anteriores, el desempeño de cada modelo se encuentra condicionado por diversos factores asociados a las características de la demanda, la disponibilidad de información y el contexto operativo. La literatura revisada coincide en que estos elementos pueden influir significativamente en la capacidad predictiva de los modelos y explicar parte de las diferencias observadas entre los resultados reportados por distintos estudios.

4.6.1. Calidad y disponibilidad de datos

La calidad y disponibilidad de datos constituye uno de los factores más recurrentes en la literatura revisada. Estudios como los de Altamirano y Caruso (2015), Ramírez Agudelo (2013) y Arrieta et al. (2017) muestran que la ausencia de registros históricos suficientes o la falta de integración de la información limitan la capacidad predictiva de los modelos además de aumentar la posibilidad de la presencia de sesgo en el pronóstico. En consecuencia, la disponibilidad de datos confiables se presenta como una condición necesaria para obtener mejoras sostenibles en la precisión del forecast.

4.6.2. Estacionalidad

La estacionalidad aparece como uno de los factores con mayor influencia sobre el desempeño de los modelos analizados y en un factor determinante al momento de seleccionar el modelo a utilizar. Investigaciones desarrolladas en el sector textil, como las de Altamirano y Caruso (2015) y Kačmárý y Lörinc (2023), evidencian que los modelos capaces de incorporar patrones estacionales presentan mejores resultados en industrias sujetas a ciclos de consumo recurrentes y temporadas comerciales definidas.

4.6.3. Variabilidad y ruido

La presencia de alta variabilidad y valores atípicos constituye otro factor crítico identificado en la literatura. Medina Samaniego (2021) y Vivas Arequipa (2025) muestran que, a medida que aumenta la complejidad de la demanda, los modelos tradicionales pueden perder capacidad explicativa, favoreciendo el uso de técnicas más flexibles como Machine Learning. Asimismo, el ruido generado por promociones, cambios de consumo, eventos extraordinarios o registros atípicos que no hayan sido registrados puede dificultar la identificación de patrones reales de comportamiento, afectando la precisión del forecast, futura trazabilidad y construcción de bases de datos. En este contexto, herramientas avanzadas permiten detectar relaciones más complejas y mejorar la capacidad predictiva; sin embargo, su implementación requiere una adecuada preparación organizacional, incluyendo disponibilidad de datos confiables, infraestructura tecnológica y capacidades analíticas que permitan aprovechar efectivamente estos modelos dentro de los procesos de planificación.

4.6.4. Nivel de agregación

El nivel de agregación constituye otro factor relevante para el desempeño de los modelos de forecasting. Como se observó en la sección 4.4.2, los estudios revisados emplean distintos niveles de análisis, incluyendo SKU individuales, familias de productos y categorías

completas. La evidencia sugiere que los pronósticos realizados sobre niveles más agregados suelen presentar menor variabilidad y, por ende, menores errores de predicción. Sin embargo, esta estabilidad puede reducir el nivel de detalle necesario para la toma de decisiones operativas o de permanencia de portfolio. En contraste, los pronósticos a nivel de SKU permiten una planificación más específica, aunque se encuentran más expuestos a fluctuaciones de demanda, valores atípicos y disponibilidad de datos. Por lo tanto, la selección del nivel de agregación debe responder al objetivo de planificación y al grado de precisión requerido por la organización.

4.6.5. Horizonte de pronóstico

El horizonte de pronóstico también influye directamente en el desempeño de los modelos analizados. Como se observó en la sección 4.4.3, los estudios revisados utilizan horizontes que varían desde períodos diarios y mensuales hasta proyecciones semestrales o anuales. La evidencia sugiere que los pronósticos de corto plazo suelen presentar menores niveles de error debido a una menor exposición a cambios en el entorno. En contraste, a medida que aumenta el horizonte de planificación, se incrementa la incertidumbre asociada a factores como variaciones en el mercado, cambios en el comportamiento del consumidor y condiciones económicas. Por esta razón, la selección del horizonte debe estar alineada con los objetivos de planificación, con la capacidad del modelo para capturar adecuadamente la dinámica de la demanda y con el entorno macroeconómico donde se desarrollará el modelo.

4.6.6. Entornos VUCA y escenarios de incertidumbre


Finalmente, los estudios revisados coinciden en que la volatilidad, incertidumbre, complejidad y ambigüedad del entorno afectan significativamente la precisión de los pronósticos. Como se desarrolló en el marco teórico, los entornos VUCA dificultan la extrapolación de patrones históricos y reducen la estabilidad de las proyecciones. En este contexto, diversos autores destacan la importancia de complementar los modelos estadísticos con análisis de escenarios, monitoreo continuo de la demanda y procesos integrados de S&OP que permitan ajustar oportunamente los planes ante cambios inesperados. La capacidad de adaptación frente a la incertidumbre se convierte entonces en un factor tan relevante como la precisión estadística del modelo utilizado.

4.7. Implicancias para la industria textil argentina

Los resultados analizados adquieren una relevancia particular para la industria textil argentina, un sector que opera en un entorno caracterizado por inflación, variaciones de poder adquisitivo, variaciones en el poder adquisitivo, cambios frecuentes en las condiciones comerciales y una elevada incertidumbre en la planificación de mediano y largo plazo. En este contexto, la gestión de la demanda no puede depender exclusivamente de proyecciones estáticas, sino que requiere capacidades de adaptación continua y evaluación permanente de escenarios alternativos. La literatura identifica al poder adquisitivo como una de las principales variables exógenas que condicionan el comportamiento de las ventas en la industria textil, debido a que modifica directamente la capacidad de compra de los consumidores y altera los patrones de consumo del mercado (Altamirano & Caruso, 2015).

La disminución del poder adquisitivo no solo reduce el volumen de consumo, sino que también modifica su composición. En escenarios de menor capacidad de compra, los consumidores tienden a priorizar productos esenciales, postergar compras de mayor valor y orientar sus decisiones hacia artículos con descuentos o promociones. Como consecuencia, las empresas textiles no solo enfrentan variaciones en el nivel total de ventas, sino también cambios en la participación de las distintas categorías de productos, aspecto que incrementa la complejidad del proceso de planificación de la demanda.

Figura 3. Clasificación ABC de productos textiles según su participación en las ventas



Fuente: (Altamirano & Caruso, 2015)

La Figura 3 evidencia que un número reducido de productos concentra la mayor parte de las ventas, mientras que una gran cantidad de referencias presenta una participación significativamente menor. En contextos donde el poder adquisitivo de los consumidores disminuye, la composición de esta demanda puede modificarse, haciendo que determinados productos estratégicos incrementen o reduzcan su participación relativa. En consecuencia, la segmentación ABC constituye una herramienta complementaria para priorizar el esfuerzo de pronóstico sobre aquellos artículos cuyo comportamiento tiene mayor impacto económico para la organización.

La evidencia revisada sugiere que las empresas textiles deberían complementar los modelos de forecasting con procesos formales de análisis de escenarios, permitiendo evaluar planes de demanda bajo supuestos base, optimistas y pesimistas. Esta práctica resulta especialmente relevante en contextos donde factores económicos y comerciales pueden modificar rápidamente los patrones de consumo y afectar las decisiones de abastecimiento, producción e inventario.

La apertura comercial constituye otro factor que incrementa la complejidad del entorno competitivo de la industria textil argentina. La mayor disponibilidad de productos importados intensifica la competencia sobre los fabricantes nacionales, especialmente cuando provienen de economías con menores costos de producción o mayores escalas industriales. En estos escenarios, la competencia basada exclusivamente en precios puede reducir la participación de mercado de la producción local, afectando los niveles de actividad, el empleo y la utilización de la capacidad instalada de la industria textil (Pinazo, 2012). Desde esta perspectiva, la planificación de la demanda adquiere un rol estratégico, ya que permite optimizar los niveles de producción e inventario para responder con mayor eficiencia a un mercado cada vez más competitivo. Asimismo, la evidencia sugiere que el fortalecimiento de la industria nacional requiere un equilibrio entre la apertura comercial y políticas que favorezcan la competitividad del sector, promoviendo condiciones que permitan sostener la producción local, el empleo y el consumo interno sin eliminar los beneficios derivados del comercio internacional y como resultado; incrementar la estabilidad de la demanda gracias a un aumento del poder adquisitivo (Cazon , Kennedy, & Weksler , 2023). En este sentido, el fortalecimiento del mercado interno constituye un elemento relevante para la sostenibilidad de la industria textil. Políticas orientadas a preservar la competitividad de la producción nacional, fomentar el empleo formal y sostener el poder adquisitivo de los hogares contribuyen a generar una demanda interna más estable, condición que favorecerían la

efectividad de los procesos de planificación de la demanda y reduce la incertidumbre operativa de las empresas.

Asimismo, la dependencia de materias primas e insumos importados incrementa la importancia de una adecuada planificación. Variaciones del tipo de cambio, restricciones comerciales o demoras en el abastecimiento afectan directamente la disponibilidad de materiales necesarios para la producción. Bajo estas condiciones, un error de pronóstico puede generar no solo pérdidas de ventas, sino también dificultades para reponer inventarios en los tiempos requeridos, debido a los mayores lead times asociados al abastecimiento internacional (Pinazo, 2012).

Asimismo, la literatura muestra que la selección del modelo de pronóstico debe responder a las características de la demanda y a la realidad operativa de cada organización. Si bien las técnicas de Machine Learning presentan resultados prometedores, muchas empresas del sector aún operan con sistemas de información limitados o con procesos de planificación poco integrados, lo que dificulta la adopción efectiva de herramientas avanzadas. En consecuencia, la prioridad para gran parte de la industria textil argentina debería centrarse en fortalecer la calidad de los datos, consolidar procesos de planificación y desarrollar esquemas de abastecimiento más flexibles antes de avanzar hacia soluciones de mayor complejidad tecnológica.

Finalmente, la comparación de los estudios revisados permite observar que muchas de las metodologías de forecasting fueron desarrolladas y validadas en economías relativamente estables. En contraste, la industria textil argentina opera en un entorno donde el poder adquisitivo, el consumo interno y las condiciones macroeconómicas presentan variaciones frecuentes, generando patrones de demanda menos estables que los observados en otros países. Por ello, además de seleccionar adecuadamente el método estadístico, resulta necesario incorporar variables macroeconómicas y procesos de planificación colaborativa que permitan adaptar continuamente los pronósticos a las condiciones del mercado (Braun & Llach, 2010).

Por lo tanto, el principal aporte de los métodos estadísticos para la industria textil argentina no radica únicamente en mejorar la precisión del forecast, sino en proporcionar una base más sólida y confiable para la toma de decisiones en entornos de alta incertidumbre, permitiendo construir organizaciones más resilientes y con mayor capacidad de respuesta frente a cambios del mercado.

5. Conclusiones

5.1. Cumplimiento del objetivo general y principales hallazgos

El objetivo general de la presente investigación fue analizar, a partir de la literatura académica y estudios de caso, la eficiencia de distintos métodos estadísticos de pronóstico de demanda en contextos de alta complejidad y variabilidad característicos de la industria textil. El propósito fue evaluar su impacto en la reducción del error de forecast en comparación con metodologías empíricas tradicionales, contribuyendo a mejorar la toma de decisiones en planificación de producción, compras e inventarios. A partir de la revisión sistemática de la literatura y del análisis comparativo de los estudios seleccionados, puede afirmarse que dicho objetivo fue alcanzado satisfactoriamente. La evidencia recopilada permitió identificar las principales metodologías estadísticas empleadas para el pronóstico de demanda, analizar su desempeño en distintos contextos de aplicación y evaluar su contribución a la reducción del error de forecast respecto a enfoques tradicionales basados exclusivamente en juicio experto o procedimientos empíricos. Asimismo, fue posible reconocer las variables que condicionan la precisión de los modelos, así como las implicancias que estos resultados tienen para la planificación de la demanda dentro de la industria textil, especialmente en entornos de elevada incertidumbre como el argentino.

Como resultado de este análisis, se identificaron los siguientes hallazgos principales:

En primer lugar, los métodos estadísticos demostraron una mayor precisión que los enfoques basados exclusivamente en juicio experto o procedimientos empíricos, evidenciando mejoras en indicadores como MAPE, MAE y RMSE, así como en la gestión de inventarios, abastecimiento y niveles de servicio.

En segundo lugar, se comprobó que no existe un método de forecasting universalmente superior. La efectividad de cada modelo depende de factores como la calidad de los datos, la estacionalidad, la variabilidad de la demanda, el horizonte de planificación, las características de la serie analizada y el contexto en el que estos son aplicados.

Asimismo, se identificó que la calidad de los datos constituye uno de los principales factores que condicionan el desempeño de cualquier metodología de pronóstico. La disponibilidad de información confiable resulta determinante para obtener proyecciones precisas, independientemente de la complejidad del modelo utilizado.

Otro hallazgo importante fue el potencial de las técnicas de Machine Learning para mejorar la precisión del forecast en entornos de alta variabilidad. No obstante, su implementación requiere una adecuada infraestructura tecnológica, disponibilidad de datos y procesos de planificación consolidados.

De igual manera, la investigación evidenció que el contexto macroeconómico influye directamente sobre la precisión del pronóstico. Variables como el poder adquisitivo, la apertura comercial, la dependencia de materias primas importadas y la volatilidad económica modifican el comportamiento de la demanda, por lo que ningún modelo estadístico puede garantizar resultados precisos si estas condiciones no son consideradas dentro del proceso de planificación. En consecuencia, el forecasting debe complementarse con el monitoreo de variables externas y la construcción de escenarios que permitan adaptar las decisiones a los cambios del mercado.

Finalmente, el análisis permitió concluir que el forecasting trasciende la reducción del error estadístico y constituye una herramienta de apoyo para la toma de decisiones. Cuando los pronósticos se integran dentro de procesos de Sales and Operations Planning (S&OP), proporcionan una base objetiva para coordinar las áreas comerciales, financieras y operativas, facilitando la evaluación de escenarios, la asignación de recursos y una respuesta más ágil frente a cambios en la demanda. En el caso de la industria textil argentina, esta integración adquiere una importancia aún mayor debido a la elevada incertidumbre del entorno económico.

5.2. Cumplimiento de objetivos específicos

En relación con el primer objetivo específico, identificar y describir, a partir de la literatura y estudios previos, las variables críticas que influyen en el pronóstico de demanda en el sector textil y en industrias comparables, así como su relevancia para mejorar la precisión de los modelos estadísticos; este fue alcanzado mediante la revisión y análisis de los estudios seleccionados. La investigación permitió identificar que variables como la calidad de los datos, la estacionalidad, la variabilidad de la demanda, el horizonte de planificación, el nivel de agregación y, particularmente en el contexto argentino, el poder adquisitivo de los consumidores, influyen directamente en la precisión del forecast y en la selección de la metodología más adecuada para cada organización.

Respecto al segundo objetivo específico, analizar los supuestos y escenarios de simulación propuestos en investigaciones que aborden entornos VUCA, con el fin de comprender cómo afectan la robustez y aplicabilidad de los pronósticos de demanda; la revisión evidenció que la construcción de escenarios base, optimistas y pesimistas fortalece la planificación y permite responder con mayor flexibilidad frente a cambios inesperados del entorno. Asimismo, se observó que el monitoreo continuo de variables externas y la incorporación de procesos de ajuste favorecen la robustez de los pronósticos en contextos caracterizados por elevada incertidumbre.

Respecto al tercer objetivo específico, revisar y sistematizar estudios académicos y casos de aplicación que utilicen modelos estadísticos de pronóstico de demanda en la industria textil o sectores comparables, identificando variables, parámetros y segmentaciones utilizadas en cada enfoque; este se cumplió mediante la elaboración de la matriz comparativa de estudios y el análisis metodológico desarrollado en la investigación. Esto permitió identificar las metodologías más utilizadas, las variables consideradas por cada autor y las principales aplicaciones de herramientas como la suavización exponencial, ARIMA, Machine Learning, simulación Monte Carlo, análisis ABC y modelos bayesianos.

Finalmente, en relación con el cuarto objetivo específico, comparar los resultados reportados en la literatura entre metodologías empíricas y modelos estadísticos, analizando los errores de predicción (MAPE, WAPE) y evaluando en qué medida los métodos cuantitativos han demostrado mejoras en precisión y confiabilidad del forecast, la evidencia recopilada confirmó que los métodos estadísticos presentan, en términos generales, mejores niveles de precisión y confiabilidad que los enfoques empíricos. Sin embargo, también se concluye que la magnitud de estas mejoras depende de la calidad de la información disponible, de las características de la demanda y del contexto económico en el que se desarrolla la planificación, reforzando la importancia de complementar los modelos cuantitativos con el análisis de variables externas y procesos de planificación colaborativa.

En relación con la hipótesis planteada, la evidencia revisada permite concluir que esta encuentra sustento en la literatura analizada. Los estudios muestran que la aplicación de métodos estadísticos mejora la precisión del forecast respecto a enfoques basados principalmente en juicio experto o procedimientos empíricos, generando además beneficios operativos en la gestión de inventarios, abastecimiento y coordinación de la cadena de suministro. No obstante, la magnitud de estas mejoras depende de factores como la calidad de los datos, las características de la demanda y el contexto de aplicación, lo que confirma que la efectividad del forecasting trasciende la metodología utilizada.

5.3. Verificación de la hipótesis

En relación con la hipótesis planteada, la evidencia revisada permite concluir que esta encuentra sustento en la literatura analizada. Los estudios revisados demuestran que la aplicación de métodos estadísticos mejora la precisión del forecast respecto a enfoques basados principalmente en juicio experto o procedimientos empíricos, generando además beneficios operativos en la gestión de inventarios, abastecimiento y coordinación de la cadena de suministro.

Sin embargo, la investigación también permitió comprobar que la precisión del pronóstico no depende exclusivamente de la metodología utilizada. Factores como la calidad de los datos, la estacionalidad, la variabilidad de la demanda y, especialmente en el contexto argentino, variables macroeconómicas como el poder adquisitivo de los consumidores, influyen de manera significativa en el desempeño de los modelos de forecasting. En consecuencia, la evidencia respalda la hipótesis planteada, pero también demuestra que la efectividad de los métodos estadísticos se encuentra condicionada por las características de la demanda tanto del sector como del contexto en el que son aplicados.

5.4. Beneficios de los usos del forecasting estadísticos

La literatura revisada evidencia que la aplicación de métodos estadísticos de forecasting genera beneficios que trascienden la mejora de la precisión de los pronósticos. En primer lugar, permite optimizar la gestión de inventarios mediante una mejor estimación de la demanda futura, reduciendo tanto el riesgo de sobrestock como la ocurrencia de quiebres de stock.

Asimismo, una mayor precisión en las proyecciones favorece la planificación de compras, producción y abastecimiento, contribuyendo a una utilización más eficiente de los recursos disponibles, a una mejor coordinación entre las distintas áreas de la organización y a la adaptación de las estrategias de abastecimiento frente a cambios en la demanda. Adicionalmente, la construcción de bases de datos históricas más robustas y el seguimiento sistemático del comportamiento de los SKU permiten generar información valiosa para evaluar el desempeño del portafolio de productos, identificar referencias con baja rotación, detectar oportunidades de racionalización y respaldar decisiones relacionadas con lanzamientos, discontinuaciones o ajustes de surtido. Esto resulta particularmente relevante en industrias como la textil, donde la estacionalidad y los cambios en las preferencias de los consumidores pueden generar importantes fluctuaciones en la demanda.

Finalmente, otro beneficio relevante corresponde al fortalecimiento de los procesos de toma de decisiones. La utilización de herramientas cuantitativas proporciona una base más objetiva para la planificación, reduciendo la dependencia exclusiva del juicio experto y facilitando la evaluación de escenarios alternativos frente a contextos de incertidumbre. Además, cuando los pronósticos se integran dentro de procesos de Sales and Operations Planning (S&OP), contribuyen a una mejor alineación entre las áreas comerciales, financieras y operativas, favoreciendo respuestas más ágiles y coordinadas frente a cambios en el mercado.

5.5. Recomendaciones para empresas del sector textil

A partir de los hallazgos obtenidos en la presente investigación, se proponen las siguientes recomendaciones para las empresas del sector textil interesadas en fortalecer sus procesos de planificación de la demanda.

En primer lugar, resulta fundamental invertir en la calidad y disponibilidad de los datos. La evidencia revisada demuestra que la precisión de los modelos depende en gran medida de la consistencia, actualización e integridad de la información utilizada. Por ello, las organizaciones deberían priorizar la estandarización de registros, la integración de fuentes de información y el monitoreo continuo de la calidad de los datos para aumentar la confiabilidad de los mismos.

En segundo lugar, se recomienda seleccionar las metodologías de forecasting en función de las características de la demanda y no únicamente por el nivel de sofisticación tecnológica del modelo. Los resultados analizados muestran que distintos enfoques pueden presentar mejores desempeños según la estacionalidad, variabilidad, horizonte de planificación y disponibilidad de información histórica. Se recomienda complementar los pronósticos con análisis de escenarios y revisiones periódicas de la demanda. En entornos caracterizados por inflación, cambios en el consumo y elevada incertidumbre, la utilización de escenarios base, optimistas y pesimistas permite anticipar riesgos y mejorar la capacidad de respuesta frente a cambios del mercado.

Por otro lado, las empresas deberían fortalecer procesos integrados de planificación como Sales and Operations Planning (S&OP), promoviendo una mayor coordinación entre las áreas comerciales, financieras, productivas y de abastecimiento. La integración del forecast dentro de estos procesos permite transformar la información en decisiones concretas y mejorar la capacidad de adaptación organizacional.

Finalmente, la incorporación de herramientas avanzadas de analítica y Machine Learning debería realizarse de manera gradual y alineada con el nivel de madurez digital de cada

organización. Antes de adoptar soluciones de alta complejidad, resulta recomendable consolidar la calidad de los datos, los procesos de planificación y las capacidades analíticas internas que permitan aprovechar efectivamente estas tecnologías.

5.6. Limitaciones del estudio y futuras líneas de investigación

La principal limitación de la presente investigación radica en su carácter documental, ya que los resultados se basan en el análisis de estudios previos y no en la aplicación práctica de modelos de forecasting sobre datos reales de empresas del sector textil argentino. Asimismo, las investigaciones revisadas fueron desarrolladas en distintos contextos geográficos, económicos y organizacionales, lo que puede limitar la generalización de algunos resultados.

Por otra parte, la disponibilidad de información y métricas reportadas varió entre los estudios analizados, dificultando la comparación directa de los resultados obtenidos por las diferentes metodologías.

Como futuras líneas de investigación, se recomienda desarrollar estudios aplicados que evalúen el desempeño de distintos modelos de forecasting utilizando datos reales de empresas textiles argentinas. Sería de interés analizar el impacto de técnicas avanzadas de Machine Learning e Inteligencia Artificial en contextos caracterizados por alta volatilidad e incertidumbre, así como profundizar en la integración de los procesos de forecasting con metodologías de Sales and Operations Planning (S&OP).

6. Bibliografía

- Altamirano, M., & Caruso, G. (2015). Aplicación de herramientas de toma de decisiones en la gestión de la cadena de suministro a una PyME textil de la región. Universidad nacional de Mar del Plata.
- Amico, F. (2013). Crecimiento, distribución y restricción externa en Argentina. *Revista Argentina de economía*.
- APICS. (2021). *APICS Dictionary* (16th ed.). Association for Supply Chain Management (ASCM).
- Arrieta, C., Diaz Torrez , D., Garzon Vinasco, J., & Donoso, C. (2017). *El software como optimizador de oferta y demanda en el sector textil*. Uninpahu, Colombia: Investigacion e innovacion en ingenierias.
- Boada, J. (2016). *Sistema de proyección de la demanda. Caso práctico de predicción automatizada en empresas de venta por catálogo*. Antioquía, Colombia: Perspectiva Empresarial.
- Braun, M., & Llach, L. (2010). *Macroeconomía Argentina*. Buenos Aires: Alfaomega.
- CAME. (2025). *Informe de Producción Industrial Pyme: Sector textil e indumentaria*. Obtenido de Informacion asamblea general ordinaria:
<https://www.redcame.org.ar/novedades/14369/las-ventas-por-el-dia-de-la-madre-2025-bajaron-35-anual>
- Cazon , F., Kennedy, D., & Weksler , G. (2023). *Salario en paridad de poder adquisitivo internacional*. Buenos Aires: Universidad de Buenos Aires.
- CEPAL. (20 de 01 de 2023). *Nuevas estadísticas sobre la industria manufacturera en América Latina*. Recuperado el 20 de 09 de 2025, de
<https://www.cepal.org/es/notas/nuevas-estadisticas-la-industria-manufacturera-america-latina?>
- Chaman L, J. (2020). *Fundamentals of Demand Planning & Forecasting* (3era ed.). New York: Graceway Publishing Company, Inc. Obtenido de
<https://ibf.org/books/fundamentals-of-demand-planning-and-forecasting-3-110>
- Gonzales Perez, C. (2020). Pérdida del poder adquisitivo versus disminución del tiempo de trabajo socialmente necesario. *Revista Iberoamericana de las ciencias sociales y humanísticas*.
- Gonzales, M. (2011). *La relación de largo plazo entre*. Argentina: Fcultad latinoamericana de ciencias sociales.
- Huaca León, W. (2018). Metodología para la planificación de la demanda en una empresa del sector textil. Universidad Militar Nueva Granada.

- Hugos, M. (2003). *Essentials of supply chain management*. New Jersey: John Wiley & Sons, Inc.
- Hyndman, J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3era ed.). Monash University. Obtenido de <https://otexts.com/fpp3/>
- IJSRET. (2024). Demand Forecasting in Textile Industry for Weaving Materials Using AI. *International Journal of Scientific Research & Engineering Trends*, 10. Obtenido de https://ijsret.com/wp-content/uploads/2024/05/IJSRET_V10_issue3_254.pdf?utm_source=chatgpt.com
- ILO. (2022). *The state of the apparel and footwear industry: Employment, automation and their gender dimensions*. International Labour Organization. Obtenido de https://www.ilo.org/sites/default/files/wcmsp5/groups/public/%40ed_emp/documents/publication/wcms_835423.pdf
- INDEC. (2024). *Índice de precios al consumidor*. Argentina: Instituto Nacional de Estadística y Censos. Recuperado el 2025, de <https://www.indec.gob.ar/indec/web/Nivel4-Tema-3-5-31>
- Ivanov, D., Tsipouladis, A., & Schonberger, J. (2021). *Global Supply Chain and Operations Management: A Decision-Oriented Introduction to the Creation of Value*. Springer. (3 ed.).
- Jebbor, I., Benmamoun, Z., & Hachimi, H. (2024). Forecasting supply chain disruptions in the textile industry using machine learning: A case study Predicting supply chain disruptions in the textile sector using data analytics. *Ain Shams Engineering Journal*. Obtenido de <https://www.sciencedirect.com/science/article/pii/S2090447924004970?via%3Dihub>
- Kacmary, P. (2023). Sustainability. En *Forecasting of seasonal textile products using Holt–Winters method*. (págs. 15(21), 15517). Obtenido de . <https://doi.org/10.3390/su152115517>
- LLada, M. (2022). *Forecasting del PBI argentino*. Buenos Aires: Revista de economía política de Buenos Aires.
- Makridakis, S., Wheelwright, C., & Hyndman, J. (1998). *Forecasting: Methods and Applications* (3era ed.). Wiley.
- Medina Samaniego, H. (2021). Aplicación de técnicas de minería de datos y análisis de tendencias para el pronóstico de demanda en las MiPymes del sector textil. Universidad de Cuenca.
- Mohd Aris, N., Sarah Omar, S., & Hashim, F. (2014). *VUCA: THEORIES, CONCEPTS, AND ITS REMEDY*.
- Mora Garcia, L. (2010). *Diccionario de logística y SCM*. Colombia: High Logistics.
- Nahmias, S. (2015). *Análisis de la producción y las operaciones* (7th ed.). McGrawHill.

- Petropoulos, F., Hyndman, R., Bergmeir, C., & Talagala, T. (2022). *Forecasting: Theory and practice*. International Journal of Forecasting. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0169207021001758?via%3Dihub>
- Pinazo, G. (2012). *Comentarios sobre la relación entre el crecimiento y el empleo en la Argentina de los últimos años*. Santiago del Estero, Argentina: Núcleo Básico de Revistas Científicas Argentinas.
- Ramírez Agudelo, S. (2013). Comparación de metodologías estadísticas para el pronóstico de demanda de productos de difícil estimación. Universidad Pontificia Bolivariana.
- Rodríguez, J., Peña, L., & Camba, A. (2023). *Políticas de oferta e inflación, reformas procompetitivas para estabilizar los precios y proteger el poder adquisitivo*. Buenos Aires.
- Silver, E., Pyke, D., & Thomas, D. (2016). *Inventory and Production Management in Supply Chains* (4th ed.). CRC Press.
- Valencia Cardenas, M., Diaz Serna, F., & Correa Morales, J. (2014). *Inventory planning with dynamic demand. A state of art review*. Medellin: Universidad Nacional de Colombia: Facultad de Minas.
- Valera García, J. (2022). Implementación de una propuesta de mejora en la planificación de la demanda para optimizar el nivel de inventarios de la empresa Tex Javier Sport EIRL. Universidad Peruana de Ciencias Aplicadas.
- Vandeput, N. (2023). *Demand Forecasting Best Practices*. Manning Publications.
- Vivas, P. (2025). *modelo estadístico para la optimización de la planificación en consumo masivo de la empresa de lácteos S.A*. Arequipa: UDLA escuela de negocios.

7. Anexos

7.1. Cuadros comparativos de estudios revisados

Tabla 15. Matriz maestra de extracción documental

Autor	Año	País	Industria	Problema-Situación Diagnosticada	Evidencia	Objetivo	Métodos utilizados	KPI utilizados	Principales resultados	Mejora reportada	Relación con la hipótesis
Altamirano & Caruso	2015	Argentina	Textil (PyME confección)	Escasez de datos históricos confiables y dependencia del juicio experto para la toma de decisiones	Decisiones centralizadas en el dueño y sustentadas principalmente en su experiencia; registros de ventas distribuidos en 96 planillas Excel.	Desarrollar estrategias de planificación bajo incertidumbre	Monte Carlo, PAJ, SARIMA, Suavización exponencial	TEA, TED	Los métodos estacionales mostraron mejor desempeño para representar la demanda textil	Reducción de ineficiencias operativas	Apoya la hipótesis. Los modelos estadísticos mejoran la toma de decisiones frente a enfoques empíricos
Valera García	2022	Perú	Textil (indumentaria deportiva)	Planificación reactiva de la producción y deficiente gestión de inventarios	No se cuenta con un área formal de planeamiento; la producción se define en base a los pedidos recibidos y se observaron desviaciones del pronóstico fuera de los límites aceptables.	Optimizar inventarios mediante mejora del forecast	Clasificación ABC, Suavización exponencial, Solver	MAD, CS, Señal de seguimiento	Reducción de inventarios y mejora en planificación	-13% costos de inventario; -36% costos de almacenamiento	Apoya fuertemente la hipótesis

Huaca León	2018	Colombia	Textil (tela cortina)	Deficiencias en la planificación asociadas a rupturas de stock e incumplimientos de despacho	El estudio identifica dependencia del juicio del administrador en el proceso de forecasting y procesamiento manual en Excel de información extraída del ERP.	Diseñar una metodología de planificación de demanda	Suavización Exponencial Doble	Rotación de inventarios	Mejora de reposición y disponibilidad	Optimización del abastecimiento	Apoya la hipótesis
Medina Samaniego	2021	Ecuador	Textil (MiPymes)	Alta volatilidad de mercado, calidad deficiente de datos y limitaciones de los modelos tradicionales	>30 % de datos faltantes y dificultad para captar información contextual.	Mejorar el forecast incorporando señales externas	Ridge Regression, SVR, Random Forest, Google Trends	MAD, MAPE, MSE, RMSE, R^2	Los modelos ML superaron a modelos tradicionales	Mejora entre 5% y 20% en precisión	Apoya fuertemente la hipótesis
Jebbor et al.	2024	Marruecos	Textil (manufactura de prendas)	Disrupciones en la cadena de suministro	Entorno dinámico que supera las capacidades de herramientas convencionales.	Anticipar fallas y riesgos mediante ML	Random Forest, KNN, SVM	Accuracy y métricas de clasificación	Alta capacidad predictiva para interrupciones	Incremento de resiliencia de la cadena	Apoya parcialmente la hipótesis

Arrieta et al.	2017	Colombia	Textil (confección)	Falta de integración y control de la información en los procesos de oferta-demanda	Estudio de 6 empresas y encuesta a 30 ejecutivos; 68 % manifestó desconocer estándares y herramientas de buenas prácticas para la cadena de abastecimiento.	Automatizar la gestión oferta-demanda	ERP Idempiere	Tiempo de almacenamiento	Mejor coordinación de procesos	Reducción de errores manuales	Apoya indirectamente la hipótesis
Prapti Jain	2024	India	Textil (tejidos y materiales)	Ineficiencia operativa, limitación de datos	Desperdicio de materiales y restricciones de acceso/tamaño de muestra.	Aplicar IA para mejorar el forecast de insumos	IA y modelos de regresión	MSE	Mejor desempeño predictivo que enfoques tradicionales	No reportada cuantitativamente	Apoya la hipótesis
Vivas Arequipa	2025	Ecuador	Consumo masivo (lácteos)	Desabastecimiento y variabilidad de demanda	Problemas de stock por baja precisión del pronóstico. Flata de alineación con el comportamiento del consumidor	Comparar ARIMA/SARIMA versus ML	ARIMA, SARIMA, ML	Métricas de precisión	ML superior en presencia de outliers	Mejor desempeño predictivo	Apoya la hipótesis
Boada	2017	Venezuela	Cosméticos	Insuficiencia de indicadores. Ciclos cortos y fuerte dependencia promocional	reestructuración manual de datos para crear esquemas útiles.	Automatizar la predicción de demanda	Regresión múltiple, Bayesiano	MSE	Mejora de las proyecciones comerciales	Mayor precisión respecto al juicio experto	Apoya la hipótesis

Ramírez Agudelo	2013	Colombia	Manufactura	Escasez de datos históricos y elevada variabilidad de la demanda	Solo se disponía de 12 observaciones mensuales y existían fuertes fluctuaciones asociadas a promociones, limitando la aplicación de modelos estadísticos tradicionales.	Comparar enfoques estadísticos para series cortas	Bayesiano vs Tradicional	MAPE	Método bayesiano más robusto	Menor error de pronóstico	Apoya la hipótesis
Valencia - Cárdenas	2015	Multipaís	Multisectorial	Demanda dinámica e incertidumbre	N/A (revisión de modelos)	Revisar modelos de planificación de inventarios	Revisión de modelos dinámicos	Costos y nivel de servicio	Evidencia necesidad de modelos adaptativos	No aplica	Apoya indirectamente la hipótesis
Petropoulos et al.	2022	Internacional	General	Brecha entre teoría y práctica del forecasting	N/A (revisión sistemática)	Revisar el estado actual del forecasting	Revisión sistemática	MAPE, RMSE, sMAPE	Los modelos cuantitativos muestran ventajas consistentes	No aplica	Apoya la hipótesis
Nahmias	2007	Internacional	General	Error de pronóstico y control de inventarios	N/A (libro de referencia)	Desarrollar fundamentos analíticos del forecasting	Promedios móviles, Holt, Winters, ARIMA	MAD, MSE, Tracking Signal	Establece bases metodológicas para medir precisión	No aplica	Sustento teórico de la hipótesis
Llada, M.	2022	Argentina	Macroeconomía	Retraso en la publicación oficial del PBI (80 días).	N/A (estudio macroeconómico)	Realizar nowcasting y backcasting del crecimiento del PBI.	Modelo de factores dinámicos (DFM), PCA, Filtro de Kalman.	RMSE, Test de Giacomini-White.	El modelo factorial supera a los modelos base (Naive y AR1).	Reducción del RMSE (de 0.022 a 0.010 aprox.).	Apoya la superioridad de modelos estadísticos sobre métodos simples.

González, M.	2011	Argentina	Multisectorial	Inexistencia de series oficiales de largo plazo continuas.	N/A (estudio macroeconómico)	Indagar cómo las estrategias de acumulación influyen en el salario real.	Regresión lineal, Filtro de Hodrick-Prescott.	R ² ajustado, Durbin-Watson.	Identificación del PBIpc y Tipo de Cambio como predictores del salario.	Mejora en la comprensión de ciclos históricos.	Apoya el uso de estadística para explicar variaciones de demanda (salario).
Cazón et al.	2023	Argentina	Internacional	Limitaciones de indicadores tradicionales para medir poder adquisitivo.	N/A (estudio descriptivo)	Comparar el salario y poder adquisitivo internacional mediante PPA.	Metodología de Paridad de Poder Adquisitivo (Banco Mundial).	Coefficientes PPA, Salario promedio mensual.	Construcción de una serie comparativa robusta de capacidad de compra.	No reportada (estudio descriptivo).	Sustenta la importancia de variables de poder adquisitivo.
Pinazo, G.	2012	Argentina	Manufactura (Textil)	Heterogeneidad productiva e impacto dispar en el empleo.	N/A (análisis sectorial)	Analizar la relación entre crecimiento económico y generación de empleo.	Análisis sectorial y coeficientes de productividad.	Coefficientes de empleo y elasticidad.	El sector textil es de baja productividad y alta sensibilidad al tipo de cambio.	No reportada (estudio de análisis).	Contextualiza la vulnerabilidad del sector textil.
Amico, F.	2013	Argentina	Macroeconomía	Restricción externa y volatilidad inflacionaria.	N/A (estudio macroeconómico)	Analizar el impacto de la distribución del ingreso en el crecimiento.	Modelos macroeconómicos post-keynesianos.	Tasa de inflación, Déficit fiscal, Crecimiento PBI.	La inflación actúa como transferencia de ingresos que afecta el consumo.	No reportada (estudio teórico-empírico).	Vincula inflación con erosión del poder adquisitivo.
Llach & Braun	2010	Argentina	Macroeconomía	Volatilidad extrema de la economía argentina ("montaña rusa").	N/A (libro de referencia)	Sintetizar el canon macroeconómico aplicado al caso argentino.	Modelización econométrica y análisis de corto plazo.	PBI, Consumo privado, Inversión.	El consumo es el motor procíclico de las dos terceras partes del PBI.	No reportada (Libro de texto).	Provee el sustento teórico de la función de consumo.

Fuente: elaboración propia a partir de estudios revisados

Tabla 16. Matriz comparativa metodológica de los estudios analizados

Autor	Variables críticas consideradas	Objeto de pronóstico	Unidad	Nivel de agregación	Horizonte	Método aplicado	Tipo de enfoque	Métricas	Fuente de datos	Aplicación principal	Resultado cuantitativo principal	Hallazgo metodológico principal
Altamirano & Caruso (2015)	Estacionalidad, tendencias de moda, demanda censurada, segmentación ABC, factores macroeconómicos y entorno VUCA.	Ventas de prendas textiles.	Unidades físicas.	Artículo y familia.	12 meses.	SARIMA, Holt-Winters, Monte Carlo y PAJ.	Híbrido.	MAPE, TEA, TED.	Históricos de ventas y juicio experto.	Planificación de operaciones.	Reducción aproximada del error del 20% mediante simulación.	La combinación de simulación, métodos estadísticos y juicio experto permite mejorar la precisión en entornos con escasez de datos históricos.
Valera García (2022)	Segmentación ABC, ventas perdidas y control del sesgo mediante señal de seguimiento.	Camisetas y conjuntos deportivos.	Unidades físicas.	SKU y artículo.	Mensual.	Suavización exponencial optimizada con Solver.	Estadístico tradicional.	MAD, Señal de Seguimiento.	Registros históricos de almacén.	Gestión de inventarios.	Reducción del 13% en costos de inventario.	La optimización de parámetros mejora significativamente la precisión frente a configuraciones estándar.
Medina Samaniego (2021)	Tendencias de moda, volatilidad, demanda censurada y segmentación de productos.	Camisetas, pantalones y tops.	Unidades vendidas.	Artículo y categoría.	Semanal.	Ridge, SVR y Random Forest.	Machine Learning.	MAD, MAPE, RMSE, R ² .	ERP y Google Trends.	Gestión de Supply Chain.	Mejora de precisión entre 5% y 20%.	La incorporación de variables externas mejora el desempeño predictivo en

												series cortas y volátiles.
Huaca León (2018)	Ventas perdidas, segmentación ABC y detección de tendencias.	Telas para cortina.	Metros.	Artículo y línea.	11 meses.	Suavización exponencial al doble.	Estadístico tradicional.	Rotación de inventarios.	ERP y facturación histórica.	Compras y reposición.	Mejora del nivel de servicio y reducción de quiebres de stock.	Los modelos que incorporan tendencia permiten mejorar la reposición y el abastecimiento.
Boada (2017)	Estacionalidad, lanzamientos, factores macroeconómicos y volatilidad del entorno.	Cosméticos y lociones.	Unidades / Logaritmo de demanda.	SKU y familia.	Campaña comercial.	Regresión múltiple y modelo bayesiano dinámico.	Híbrido.	MSE, Distancia de Cook.	Históricos de ventas y variables comerciales.	Planeamiento comercial y S&OP.	Mayor capacidad de reacción frente a cambios bruscos de demanda.	La combinación de regresión y modelos bayesianos mejora la adaptabilidad del forecast.
Vivas Arequipa (2025)	Estacionalidad, ventas perdidas, segmentación y detección de outliers.	Lácteos, bebidas y derivados.	Cantidad despachada.	Familia y categoría.	Diario y mensual.	ARIMA, SARIMA y Random Forest.	Comparativo Estadístico vs ML.	MSE, MAE, MAPE, RMSE.	ERP / SAP.	Inventarios y producción.	Random Forest superior en series irregulares; SARIMA superior en series estables.	La selección del modelo debe depender de las características de la serie analizada.
Ramírez Agudelo (2013)	Lanzamientos, estacionalidad e incertidumbre asociada a	Productos industriales textiles.	Unidades físicas.	Artículo.	12 meses.	Bayesiano MCMC y Optimización Tabú.	Bayesiano.	MAPE, APEt.	Históricos limitados.	Planeación logística y lanzamientos.	MAPE entre 3% y 10%.	Los modelos bayesianos presentan mayor robustez cuando la

	muestras pequeñas.											información histórica es escasa.
Kačmárý & Lörinc (2023)	Estacionalidad, tendencias de moda, lanzamientos y sobrestock asociado a errores de forecast.	Ropa de moda online.	Ventas.	Artículo.	Temporada (6 meses).	Holt-Winters e índices estacionales.	Estadístico tradicional.	RMSE.	Históricos de e-commerce.	Compras y sostenibilidad.	Reducción de desperdicio asociado al sobrestock.	Los modelos estacionales permiten alinear producción y demanda en productos con ciclos de vida cortos.
Llada (2022)	Incertidumbre, sentimiento económico, presión cambiaria.	Crecimiento del PBI.	Tasas porcentuales.	Nacional (Macroeconómico).	Corto plazo (Nowcast).	DFM (Factores Dinámicos).	Estadístico avanzado.	RMSE.	Indicadores "Hard" y "Soft" (MECON, UTDT).	Política económica / Toma de decisiones.	RMSE de 0.010 en backcast del 3er mes del trimestre.	La incorporación de fuentes no tradicionales (sentimiento) mejora la precisión en crisis.
González (2011)	Tipo de cambio real, PBI per cápita.	Salario real.	Índices (1960=100).	Nacional / Industrial.	Largo plazo (1950-2006).	Regresión con variables rezagadas.	Estadístico tradicional.	R ² .	Reconstrucción de series históricas.	Análisis de mercado de trabajo.	R ² ajustado entre 0.26 y 0.31 para el ciclo salarial.	El uso de filtros (HP) permite aislar el ciclo de la tendencia para mejor ajuste.

Cazón (2023)	Paridad de Poder Adquisitivo (PPA).	Poder de compra salarial.	Dólares PPA.	Internacional comparado.	Benchmark (2017-2022).	Método de comparación internacional PCI.	Descriptivo- Metodológico.	Ratios PPA.	Banco Mundial e informes salariales.	Benchmarking de consumo.	Argentina se ubica por debajo del promedio de la OCDE en PPA.	Los coeficientes PPA son más precisos que el tipo de cambio nominal para medir demanda.
Pinazo (2012)	Productividad, apertura comercial.	Empleo industrial.	Unidades de empleo / Valor.	Sectorial (Textil vs. otros).	Histórico.	Análisis de elasticidad producto-empleo.	Cualitativo- Cuantitativo.	Coeficientes técnicos.	Censo Económico y Lavopa (2007).	Planificación industrial.	Sector textil con alta sensibilidad a la competencia importada.	La heterogeneidad sectorial impide usar modelos macro únicos para toda la industria.
Amico (2013)	Inflación, tipo de cambio, puja distributiva.	Nivel de actividad.	Porcentajes reales.	Nacional.	Mediano plazo.	Análisis de consistencia macroeconómica.	Teórico- Empírico.	Tasas de variación.	Cuentas nacionales y registros fiscales.	Gestión de consumo interno.	La inflación erosiona el poder de compra desplazando la curva de demanda.	El análisis de demanda debe integrar la puja distributiva como variable de ruido. Debe tomar en cuenta variables

												macroeconómicas.
Llach & Braun (2010)	Ingreso disponible, expectativas, tecnología.	Consumo Privado.	Precios constantes.	Nacional Agregado.	Corto y mediano plazo.	Función de consumo keynesiana ampliada.	Teórico (Libro).	Magnitudes reales.	INDEC y series históricas.	Fundamentos de planificación.	El consumo representa aprox. el 66% de la demanda agregada.	El consumo depende del ingreso permanente y no solo del ingreso actual.

Fuente: elaboración propia a partir de estudios revisados

7.2. Glosario de términos

Tabla 17. Glosario de términos

Término	Definición
Abastecimiento	Proceso de adquisición y suministro de materiales, insumos o productos necesarios para la operación de una organización.
ARIMA	Modelo estadístico de series temporales utilizado para identificar patrones y generar pronósticos de demanda.
Bias	Indicador que mide la tendencia sistemática de un pronóstico a sobreestimar o subestimar la demanda real.
Cadena de suministro (Supply Chain)	Conjunto de procesos y actividades involucradas en el flujo de materiales, información y productos desde los proveedores hasta el cliente final.
Demanda censurada	Situación en la que las ventas observadas no representan la demanda real debido a quiebres de stock o restricciones de abastecimiento.
Forecast	Estimación cuantitativa de la demanda futura basada en datos históricos y variables relevantes.
Forecasting	Proceso de elaboración y gestión de pronósticos de demanda para apoyar la planificación y la toma de decisiones.
Horizonte de pronóstico	Período de tiempo para el cual se realiza una proyección de demanda.
Inteligencia Artificial (IA)	Conjunto de tecnologías capaces de realizar tareas de aprendizaje, análisis y predicción basadas en datos.

Machine Learning	Rama de la Inteligencia Artificial que utiliza algoritmos capaces de identificar patrones y realizar predicciones a partir de datos históricos.
MAE	Error absoluto medio utilizado para evaluar la precisión de un pronóstico.
MAPE	Error porcentual absoluto medio utilizado para medir la precisión de los pronósticos.
Outlier	Valor atípico que presenta un comportamiento significativamente diferente al resto de los datos observados.
RMSE	Raíz del error cuadrático medio, utilizada para evaluar la magnitud del error de pronóstico.
SARIMA	Extensión del modelo ARIMA que incorpora componentes estacionales en la serie temporal.
SKU	Unidad individual utilizada para identificar y gestionar productos dentro de un inventario.
S&OP	Proceso integrado de planificación que alinea las áreas comerciales, operativas y financieras para equilibrar demanda y capacidad.
Suavización exponencial	Método estadístico de forecasting que asigna mayor peso a las observaciones más recientes de una serie temporal.
Variabilidad de la demanda	Grado de fluctuación que presenta la demanda a lo largo del tiempo.
VUCA	Acrónimo de Volatilidad, Incertidumbre, Complejidad y Ambigüedad.
WAPE	Error porcentual absoluto ponderado utilizado para evaluar la precisión de los pronósticos.

Fuente: Elaboración propia