

DESARROLLO DE MODELOS DE IA PARA LA PREDICCIÓN

de la demanda de productos,
considerando variables como
el precio, la estacionalidad y
la competencia

AUTOR

Alfonso Miguel Guardado Alvarado

Desarrollo de modelos de IA para la predicción de la demanda de productos, considerando variables como el precio, la estacionalidad y la competencia

Alfonso Miguel Guardado Alvarado
2026

Desarrollo de modelos de IA para la predicción de la demanda de productos, considerando variables como el precio, la estacionalidad y la competencia

Primera Edición
Universidad Pedagógica de El Salvador
“Dr. Luis Alonso Aparicio”

Ing. Luis Mario Aparicio, Rector
Arq. Cecilia María Aparicio, Vicerrectora Ejecutiva
Ing. Manuel Aparicio, Vicerrector de Investigación e Internacionalización
Licdo. Luis Eduardo Rivera Cuellar, Vicerrector Académico
Lcda. Ligia Corpeño, Vicerrectora Administrativa
Dr. Heriberto Erquicia, Director Centro de Investigación

338.02

G914d Guardado Alvarado, Alfonso Miguel, 1979-

Desarrollo de modelos de IA para la predicción de la demanda de productos, considerando variables como precio, la estacionalidad y la competencia / Alfonso Guardado Alvarado ; diseño de portada y diagramación Celdas ediciones. --1ª ed-- San Salvador, El Salv. : Universidad Pedagógica de El Salvador Dr. Luis Alonso Aparicio, 2026.

1 recurso electrónico (69 p. : il. col. ; 25 cm)

Datos electrónicos : (1 archivo formato pdf, 1.16 mb). -<https://sistemas.pedagogica.edu.sv/repositorio/principal/>

ISBN 978-99983-65-74-2 (E-Book, pdf)

1. Demanda (teoría económica). 2. Pronóstico de ventas. 3. Inteligencia Artificial. I. Título.

Corrección de estilo: Nohemy Navas
Diseño de portada: CELDAS ediciones
Diagramación: CELDAS ediciones

El contenido de esta obra, y los conceptos vertidos en cada capítulo y su originalidad, son responsabilidad del autor que los presenta, por lo que no representa un posicionamiento institucional determinado para la Facultad o la Universidad.



Universidad Pedagógica de El Salvador “Dr. Luis Alonso Aparicio”
25 Av. Norte y Diagonal Dr. Arturo Romero, San Salvador, El Salvador, C.A.
(503) 2205-8100
www.pedagogica.edu.sv
info@pedagogica.edu.sv
Hecho el depósito que exige la ley

INDICE

Introducción	9
Capítulo I	11
Planteamiento del problema	11
Formulación del problema	11
Pregunta de investigación	12
Antecedentes	13
Justificación	18
Objetivos	19
Objetivo general	19
Objetivos específicos	19
Alcances	20
Limitaciones	21
Capítulo II	22
Marco referencial	22
Definición de modelo	22
Definiciones y conceptos básicos de la predicción de la demanda	24
Previsión	27
Predicción	27
Pronóstico	27
Demanda	27
Precio	28

Estacionalidad de un producto o servicio	28
Competencia	29
Inteligencia artificial	29
Métodos para la predicción de la demanda	29
Métodos para la predicción de la demanda considerando más de una variable: Método de regresión múltiple	37
Ejercicio de aplicación de regresión múltiple	39
Fundamentos de la inteligencia artificial y el aprendizaje automático (<i>machine learning</i>)	44
Fundamentos de la inteligencia artificial	44
Fundamentos del aprendizaje automático (<i>machine learning</i>)	47
Capítulo III	49
Metodología	49
Técnicas, instrumentos, recolección y Procedimientos de formación	51
Propuesta para el desarrollo de modelos de IA para la predicción de la demanda de productos considerando las variables de precio, estacionalidad y competencia	52
AMAZON Forecast	52
Google Vertex AI	52
GluonTS	53
Power Apps	53
Pasos para construir un modelo de pronóstico de la demanda con IA	53
Capítulo IV	56
Resultados de la investigación	56
Conclusiones	56
Recomendaciones	57
Referencias	59

Anexos	64
Anexo 1	65
MAPE (Error de porcentaje medio absoluto)	65
Ejemplo:	66
Anexo 2	67
Igualación de las columna de la matriz “Y” con la multiplicación de los intersección con la matriz central	69

INTRODUCCIÓN

La capacidad de anticipar la demanda de productos se ha convertido en un factor estratégico para las organizaciones, ya que influye directamente en la eficiencia operativa, la planificación financiera y la toma de decisiones comerciales. En entornos altamente competitivos y dinámicos, predecir la demanda permite reducir la incertidumbre, optimizar recursos y mejorar la rentabilidad. Tradicionalmente, esta tarea se ha abordado mediante métodos estadísticos y modelos matemáticos, como las series de tiempo y la regresión lineal; sin embargo, dichos enfoques presentan limitaciones para capturar relaciones complejas y no lineales entre múltiples variables.

El avance de la inteligencia artificial (IA), y el aprendizaje automático, ofrece nuevas oportunidades para mejorar la precisión de los pronósticos, gracias a su capacidad para procesar grandes volúmenes de datos y adaptarse a escenarios cambiantes.

Este estudio se centra en el desarrollo de modelos de IA orientados a la predicción de la demanda de productos, considerando variables críticas como el precio, la estacionalidad y la competencia. La investigación revisa los fundamentos teóricos y metodológicos, analiza métodos tradicionales y modernos, y propone una estructura conceptual que integra técnicas de IA con modelos estadísticos para lograr pronósticos más confiables.

El propósito es ofrecer una guía que permita diseñar modelos predictivos escalables y sostenibles, contribuyendo a la toma de decisiones estratégicas y operativas en organizaciones que buscan adaptarse a mercados cada vez más dinámicos.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

Formulación del problema

La capacidad de anticipar la demanda de productos se vuelve un factor de competencia y diferenciación para la eficiencia operativa de las organizaciones. En los entornos comerciales predecir la demanda puede dar ventajas competitivas para la planificación financiera, logística y toma de decisiones estratégicas.

Según Fierro Torres et al. (2022), la predicción puede entenderse como un proceso de pronóstico cuyo objetivo principal es anticipar eventos futuros a partir de indicios observables. El autor también señala que el éxito de un pronóstico, como herramienta predictiva, depende del grado de coincidencia entre lo estimado y la realidad observada.

La longitud del horizonte temporal y el tipo de datos que analiza el modelo (anuales, trimestrales o mensuales) dará el nivel de la efectividad de los diferentes métodos de elaboración de pronósticos. Los resultados de algunos modelos de pronósticos dan mayor precisión con datos con horizontes cortos, mientras que otros se adaptan mejor a proyecciones de largo plazo. Otros modelos, exigen que se vayan adicionando datos, mientras que otros requieren series más frecuentes como las mensuales o trimestrales. Esta clasificación técnica es retomada por Fierro Torres et al. (2022), quien cita a los autores Hanke & Wichern (2014), destacando que la elección del modelo debe considerar tanto la naturaleza de los datos como el contexto operativo, ya que el ajuste metodológico impacta directamente en la precisión del pronóstico y por consecuencia en la predicción.

El criterio MAPE (*Mean Absolute Percentage Error*) es uno de los indicadores más utilizados para evaluar la precisión de los modelos de pronóstico. Su función principal es medir el error porcentual promedio entre los valores reales y los valores pronosticados, permitiendo comparar el desempeño de distintos métodos de predicción, incluso cuando se aplican a series con diferentes escalas. En el Anexo 1 puede observarse la forma de obtener el MAPE.

Los pronósticos están justificados sobre ciencias como la matemática y la estadística, disciplinas utilizadas en las investigaciones. Pero, aun así, no garantizan que el error de la predicción por medio del pronóstico sea mínimo o eliminado. Según Fierro Torres et al. (2022), utilizar inteligencia artificial no logra superar categóricamente los métodos matemáticos y estadísticos aplicados a los pronósticos.

Surge la necesidad de predecir utilizando los pronósticos como herramienta para poder relacionar varias variables y reduciendo el error mínimo en el pronóstico. En este contexto, la aplicación de la inteligencia artificial (IA) para el desarrollo de modelos, ofrece una alternativa prometedora para mejorar la precisión de las predicciones, debido a que es una herramienta que puede ir aprendiendo a medida desarrolla las predicciones, corrigiendo y eliminando factores que permitan predicciones más certeras. Existen, aún, desafíos técnicos y metodológicos en la integración efectiva de estas variables en modelos predictivos confiables y escalables, pero la investigación y desarrollo constante en la inteligencia artificial, permitirá ir mejorando los resultados de las predicciones.

Pregunta de investigación

¿Cuáles son los fundamentos necesarios para el desarrollo de modelos de inteligencia artificial para la predicción de la demanda, integrando las variables como el precio, la estacionalidad y la

competencia, con el fin que permita mejorar la predicción de la demanda de productos?

Antecedentes

El hombre cada vez busca mejorar las condiciones de subsistencia, tratando de comprender mejor los fenómenos que lo rodean y, mejor aún, ha tratado de predecirlos, con el fin de visionar un comportamiento o reducir la incertidumbre.

Resulta fundamental delimitar qué se entiende por fenómeno; en el Diccionario de metodología de la investigación científica, Ortiz Uribe (2003) define el concepto de fenómeno:

Es el acontecimiento o proceso, tal y como aparece en la realidad frente al observador; es un objeto de estudio perceptible a los sentidos del observador; sin embargo, un mismo fenómeno no puede tener tantas percepciones como observadores lo perciban. (p. 67)

Los primeros fenómenos que preocuparon al ser humano fueron los del tipo natural, donde terremotos, eclipses solares y lunares, erupciones volcánicas, entre otros, comenzaron a ser estudiados para comprender como ocurrían, entrando en conflicto con instituciones predominantes como las religiosas.

A medida que las civilizaciones comenzaron a tener espacio y presupuesto, comenzaron a comprender los fenómenos físicos, como los aportes de Isaac Newton en el siglo XVII, donde se presentaron estudios respecto a leyes de movimiento y gravitación universal.

El desarrollo científico permitió comprender de manera más profunda los fenómenos meteorológicos, astronómicos, químicos y biológicos. A su vez, las matemáticas proporcionaron las herramientas necesarias para analizar y modelar dichos

fenómenos, posibilitando incluso la predicción de determinados comportamientos y contribuyendo así a la reducción de riesgos de diversa índole.

Otro de los fenómenos que tomó importancia para conocer el comportamiento en el tiempo y el resultado de estos al relacionarlos con variables externas, son los fenómenos económicos. En la Edad Moderna, con el surgimiento del mercantilismo (siglos XVI-XVII), se comenzaron a observar fenómenos económicos como el comercio internacional, los flujos de metales preciosos y la balanza comercial.

Con el desarrollo de la economía neoclásica en el siglo XIX, se introdujeron herramientas matemáticas para modelar el comportamiento económico. En el siglo XX y XXI, la predicción de la demanda evolucionó con métodos estadísticos y tecnologías como el *big data* y la inteligencia artificial (Roldán & Sevilla Arias, 2025).

Según Makridakis (1993), en su obra *Pronósticos. Estrategia y planificación para el siglo XXI*:

Al revés que, en la física, donde las fórmulas y relaciones establecidas no cambian a efectos prácticos, el mundo de los negocios se caracteriza por cambios rápidos. Esto crea un serio problema. La observación del pasado y las medidas actuales no son suficientes para verificar la capacidad de predicción de una teoría. Por consiguiente, las teorías no pueden utilizarse hasta que se establece de qué modo afectarán los cambios futuros a sus predicciones. Estos cambios futuros tienen que tener en cuenta el aprendizaje basado en predicciones teóricas, los movimientos contrarios y acciones realizadas como resultado del aprendizaje y las acciones previas, así como las interferencias gubernamentales (como, por ejemplo, de la Oficina de Reserva Federal) u otras. De aquí que el valor de predicción, incluso de la mejor teoría, sea limitado. Se hace imprescindible considerar el alcance de la capacidad de predicción de una teoría con vanos pronósticos de cambios futuros, acciones y reacciones competitivas y condiciones de entorno. Por ahora, los que propugnan teorías no se refieren a

sus limitaciones y a su capacidad para predecir sucesos futuros cuando las condiciones serán, con toda probabilidad, distintas a las de hoy. Sin embargo, éstos son inconvenientes que deben examinarse antes de decidir si usar o no una teoría.

Dentro de todos los estudios de los fenómenos se destaca el concepto de *predicción*. En el contexto científico, la predicción se entiende como un componente esencial del pensamiento lógico y empírico, donde se vinculan explicaciones previas con la anticipación razonada de hechos futuros. Según Ortiz Uribe (2003):

Predicción es el postulado fundamental en que se basa la actividad científica; es la consideración de que el desarrollo de los procesos existentes es predecible y verificable. Es la aplicación de una explicación ya determinada a los acontecimientos futuros. De esta manera, la explicación y la predicción científicas son, simplemente, dos aspectos distintos de una misma relación lógica. (p. 116)

Predicción científica, es el conocimiento riguroso y anticipado de lo que va a ocurrir realmente en un hecho o fenómeno, a partir de ciertos estados reales anteriores caracterizados por la concurrencia estructural de un conjunto de factores reales. (p. 116)

Desde esta perspectiva, la predicción no solo es una extensión lógica del conocimiento empírico, sino también una herramienta fundamental para la toma de decisiones estratégicas en áreas como la economía, la logística y la planificación empresarial (Makridakis, 1993). No obstante, como este último autor advierte, los entornos cambiantes y las múltiples variables externas hacen que, incluso las teorías más robustas enfrenten limitaciones importantes al intentar anticipar eventos en condiciones futuras que, con frecuencia, difieren sustancialmente de las observadas en el pasado.

La previsión se ha aplicado a muchas áreas de los negocios, como la previsión de la economía de los países fundamentada en la econometría; la predicción de fenómenos naturales como el clima,

los huracanes, los fenómenos como el niño y la niña, etc.; pero también ha sido muy útil cuando se desea predecir la demanda.

La predicción de la demanda trata de encontrar datos que permita estimar la cantidad futura de productos o servicios que los consumidores requerirán. Su objetivo es anticipar necesidades del mercado para optimizar decisiones de producción, inventario, compras y distribución.

Según Render et al. (2017) “La previsión de la demanda es esencial para la planificación de operaciones, ya que permite anticipar los recursos necesarios para satisfacer al cliente” (p. 132).

La herramienta de la predicción de la demanda aporta mucho a la gestión empresarial, donde puede ser aplicada en la planificación estratégica de las empresas. El desarrollo en la forma de predecir la demanda va desde las prácticas empíricas, los modelos matemáticos y, últimamente, los algoritmos de inteligencia artificial.

Los antecedentes del pronóstico de la demanda se remontan a la antigüedad, donde los comerciantes empleaban “métodos empíricos y observacionales para anticipar las fluctuaciones” (Cifuentes, 2021, p. 4).

En los inicios de los años del siglo XX, se introdujeron métodos como la media móvil, el suavizamiento exponencial y la extrapolación de tendencias. George Udny Yule fue pionero en el análisis de series temporales, y más adelante, Box y Jenkins desarrollaron los modelos ARIMA, fundamentales para el pronóstico moderno. A partir de los años 70, se incorporaron variables explicativas como el precio, la publicidad o el clima. La regresión múltiple y los modelos econométricos permitieron relacionar la demanda con factores externos, mejorando la precisión de las predicciones. En la nueva era, la posibilidad de administrar grandes cantidades de datos como lo es el fenómeno *big data*; además, el desarrollo del aprendizaje automático ha transformado la predicción de la demanda. Algoritmos como redes neuronales, aplicando las técnicas de árboles de decisión y modelos híbridos, permiten

anticipar la demanda en tiempo real, incluso en entornos altamente volátiles. “La inteligencia artificial ha ampliado las capacidades predictivas, permitiendo modelos adaptativos que aprenden de los datos en tiempo real” (Render et al., 2017, p. 132).

Plataformas innovadoras como SAP, Oracle Demand Planning y Amazon Forecast implementan algoritmos avanzados en entornos empresariales globales. Estos permiten revisar la data o la información histórica, las variables externas y los comportamientos del consumidor en tiempo real.

Según la documentación oficial de Amazon Web Services (AWS, s.f.), Amazon Forecast utiliza una combinación de 25 modelos de predicción, que incluyen desde algoritmos estadísticos tradicionales como ARIMA hasta redes neuronales profundas como DeepAR+ y Temporal Fusion Transformer, permitiendo a las empresas generar pronósticos precisos y adaptativos para productos con patrones de demanda complejos.

Por su parte, SAP Integrated Business Planning combina modelos estadísticos, aprendizaje automático y colaboración entre áreas para generar planes de demanda precisos y alineados con la estrategia organizacional (Morozova, s. f.).

Todas estas plataformas se basan en la creación de *modelos* para predecir la demanda. Un modelo utiliza las diferentes aplicaciones matemáticas para representar un fenómeno y que se pueda predecir el comportamiento bajo ciertas condiciones. “Un modelo es una representación de un sistema real que permite estudiar su comportamiento sin necesidad de experimentar directamente con el sistema” (Render et al., 2017, p. 132).

Con el surgimiento del método científico, los modelos comenzaron a tomar forma matemática. Galileo y Newton utilizaron ecuaciones para representar el movimiento de los cuerpos, lo que marcó el inicio de los modelos físicos deterministas. Estos modelos buscaban describir la realidad con precisión y predicción.

Con la llegada de las computadoras, surgieron los modelos computacionales capaces de procesar grandes volúmenes de datos y simular escenarios complejos.

“Los modelos computacionales permiten representar sistemas dinámicos no lineales que serían imposibles de resolver analíticamente” (Winsberg, 2010, p. 42).

Los modelos han sido robustecidos por medio de algoritmos que aprenden de los datos, por medio de la inteligencia artificial, “los modelos en la inteligencia artificial no son simplemente representaciones, sino sistemas activos que interactúan con el entorno y se adaptan a él” (Russell & Norvig, 2021, p. 27).

Justificación

La necesidad de mejorar la precisión en la predicción de fenómenos por medio de pronósticos hace que la investigación actual pueda establecer los fundamentos teóricos, técnicos y metodológicos necesarios para relacionar la inteligencia artificial para estimar la demanda de productos considerando variables como el precio, la estacionalidad y la competencia. El aprovechamiento de la inteligencia artificial, para poder manejar grandes cantidades de datos, suavizarlos y aprender de forma continua, permitirá la precisión de los resultados de los pronósticos, superando las limitaciones de los modelos tradicionales que no logran capturar relaciones no lineales ni dinámicas complejas.

La investigación permitirá estructurar una metodología que permita orientar el diseño de modelos predictivos con inteligencia artificial, facilitando la comprensión técnica y conceptual de los procesos de estimación de demanda. La toma de decisiones depende mucho de la predicción por medio de pronósticos confiables y adaptativos (Chopra & Meindl, 2019).

El beneficio de contar con precedentes de predecir la demanda considerando las variables de precio, estacionalidad y competencia,

traerá beneficios al profesional del área comercial, académicos en ingeniería y ciencias de datos, y diseñadores de sistemas informáticos que requieran criterios técnicos para estructurar modelos predictivos. Además, las empresas privadas, incluso las instituciones gubernamentales podrán utilizar esta metodología como base conceptual para futuras aplicaciones.

Proponer modelos de predicción por medio de la inteligencia artificial, contribuye a resolver el desafío de anticiparse a comportamientos de consumo con mayor exactitud, dando beneficios en la planificación de producción, la logística de abastecimiento y el control de costos. Además, puede contribuir que la lógica establecida en la investigación pueda ser integrada en futuros sistemas informáticos, adaptados a la predicción de la demanda. El estudio, también, permitirá analizar con mayor profundidad la interacción entre variables como precio, estacionalidad y competencia, facilitando la identificación de patrones ocultos y relaciones no evidentes mediante técnicas de aprendizaje automático.

Objetivos

Objetivo general

Establecer los fundamentos teóricos, técnicos y metodológicos necesarios para el desarrollo de modelos de inteligencia artificial orientados a la predicción de la demanda de productos, integrando variables como el precio, la estacionalidad y la competencia, con el propósito de mejorar la precisión en la estimación de dicha demanda.

Objetivos específicos

- Presentar los conceptos fundamentales de modelo, modelos informáticos, predicción y tipos de pronóstico, con el fin de contar con base teórica para el desarrollo de sistemas predictivos aplicados a la demanda de productos.

- Describir los métodos tradicionales y específicos de pronósticos utilizados en la predicción de la demanda, con el fin de conocer la aplicación, criterios para poderlos utilizar y las diferentes variables que se pueden relacionar.
- Exponer los fundamentos de la inteligencia artificial y el aprendizaje automático (*machine learning*), para justificar su aplicación en el diseño de modelos predictivos orientados a la demanda.
- Proponer una metodológica a seguir para el desarrollo de modelos con inteligencia artificial al momento de predecir la demanda, considerando las variables de precio, la estacionalidad y la competencia, con el fin de que se establezcan criterios técnicos y estructurales que orienten el diseño, validación y aplicación de dichos modelos en contextos comerciales.
- Evaluar las ventajas y desventajas del uso de inteligencia artificial en la predicción de demanda, para determinar su viabilidad operativa y mantener un entorno ético.

Alcances

- La investigación se orienta a la construcción de una propuesta metodológica para el diseño de modelos predictivos basados en inteligencia artificial, considerando únicamente las variables clave como precio, estacionalidad y competencia, sin implementar ni validar modelos específicos.
- La metodología a proponer no incluye la creación de la aplicación informática para simular la predicción.
- La investigación tomará los modelos ya existentes para predecir la demanda sobre las variables justificadas y los buscará la forma de potenciarlos por medio de la inteligencia artificial, sin pretender validar los métodos matemáticos.

- El estudio se limitará a la identificación y análisis de criterios técnicos, estructurales y éticos necesarios para orientar el diseño de modelos predictivos con inteligencia artificial.

Limitaciones

Las limitaciones no controlables durante la investigación son las siguientes:

- La no aplicación de la investigación con alguna empresa privada, priva de datos comerciales o actualizados, dificultando la ejemplificación y contextualización de los modelos.
- No podrá existir precisión en la comprobación de la metodología, debido a que no se simulará el modelo.
- Algunos fundamentos pueden quedar obsoletos, por la rapidez que evoluciona la temática de la inteligencia artificial.

CAPÍTULO II

MARCO REFERENCIAL

Definición de modelo

Conocer el comportamiento de la demanda siempre ha sido algo que ha interesado a los inversionistas o empresarios. En muchas de las ocasiones la predicción, se desarrolla por simple experticia en el área, estableciendo metas para cumplir un rendimiento financiero esperado; pero, en muchas ocasiones, se pierde la oportunidad de abastecer un mercado potencial. Pero ¿Qué herramienta pueden utilizar las empresas para poder predecir una variable en interés y, sobre todo, que brinde resultados certeros? Por años, se han tratado de crear análisis matemáticos y estadísticos que permitan encontrar una aplicación para la predicción de una o varias variables. Surgen propuestas como el diseño de modelos, el cual tiene como objetivo simular escenarios para poder comprender fenómenos complejos. Tiene una principal característica que es poder controlar una serie enorme de datos y relacionar una o varias variables a la vez.

Los inversionistas se interesarán en modelos científicos que les ayuden a encontrar una predicción de las variables que desean controlar o reducir el riesgo, como puede ser la demanda de un producto o sector, el precio, la competencia, etc.

Brunnello y Rocha Vargas (2010/2011) señalan que un modelo es una representación de una realidad compleja, y que modelar implica describir con precisión un sistema y sus actividades.

Acevedo-Díaz et al. (2017) explican que los modelos científicos cumplen una función mediadora entre la teoría y el mundo real, lo cual se vincula con su carácter parcialmente autónomo, respecto de ambos. Esta perspectiva permite entender que los modelos no son

simples derivaciones de teorías ni simplificaciones de la realidad, sino instrumentos con capacidad de intervención y representación, que operan con cierta independencia en la práctica científica. La investigación científica logra comprender a mayor profundidad un fenómeno cuando lo hace sobre la base de modelos, ya que les permite encontrar rasgos específicos del comportamiento en poco tiempo, en comparativa con la realidad.

En el ámbito de la investigación científica, los modelos cumplen funciones esenciales que van más allá de la simple representación. Su propósito incluye la descripción, explicación y predicción de fenómenos naturales, así como la comunicación de ideas científicas (Acevedo-Díaz et al., 2017, p. 157). Esta multifuncionalidad convierte a los modelos en herramientas clave para la construcción y validación del conocimiento, especialmente cuando se articulan con teorías y datos empíricos.

Acevedo-Díaz et al. (2017) explican que:

Un modelo puede definirse como una representación de un objetivo (el referente), el cual puede ser un objeto, fenómeno, proceso, idea o sistema. En el ámbito científico, los modelos funcionan como puentes entre las teorías y los fenómenos, facilitando el desarrollo teórico a partir de los datos y su vinculación con el mundo natural.

Los modelos teóricos en ciencia presentan rasgos epistemológicos clave como su construcción desde la teoría y los datos, su orientación hacia fines específicos, el uso de analogías teóricas y su papel como mediadores entre teoría y evidencia (Adúriz-Bravo & Ariza, 2014, p. 29). Además, los modelos científicos se utilizan para representar aspectos del mundo con diversos propósitos, siendo instrumentos primarios de representación diseñados para reflejar características del mundo real (Giere, 2004, p. 747).

Los modelos no pueden comprenderse al margen de la teoría, ya que constituyen una articulación entre los elementos observables de la realidad y los marcos conceptuales que permiten

interpretarlos. En el ámbito científico, los modelos suelen adoptar formas teóricas, matemáticas, estadísticas o heurísticas, entre otras, y funcionan como instrumentos para analizar fenómenos y anticipar su comportamiento. No obstante, su capacidad explicativa y predictiva depende de su vinculación con las teorías que los sustentan y con los datos empíricos que los alimentan, ya sea de manera parcial o integral. Otra característica importante de los modelos científicos es que tienen la capacidad de aprendizaje, ya sea en la construcción del mismo o durante el uso y las posibles actualizaciones con las que puede contar al identificar nuevas necesidades en los resultados.

Según lo planteado por Rojas (2024), el pronóstico de demanda representa un reto estratégico para las empresas, donde una estimación incorrecta puede traducirse en pérdidas económicas por mermas o en el desaprovechamiento de oportunidades comerciales.

Rojas (2024) sostiene que el campo de la ciencia de datos permite a las empresas analizar grandes volúmenes de información mediante algoritmos y técnicas científicas, lo que facilita la toma de decisiones estratégicas. En particular, destaca el uso creciente de *machine learning*, modelos estadísticos avanzados y redes neuronales para mejorar la precisión de los pronósticos de demanda. Estas herramientas, al integrar tanto datos históricos como variables externas, ofrecen una visión más completa del comportamiento del mercado. Además, el autor proyecta que las tecnologías emergentes como la inteligencia artificial y el aprendizaje automático seguirán evolucionando, potenciando las capacidades predictivas, especialmente cuando se combinan con datos en tiempo real.

Definiciones y conceptos básicos de la predicción de la demanda

Los métodos de previsión de la demanda tienen como finalidad conocer, de forma anticipada, el requerimiento futuro de los

productos y servicios por parte de los consumidores. La previsión lleva a la predicción para comenzar a estimar con precisión, la demanda de los clientes, y, en caso sea necesario, considerando variables que desean controlarse.

La previsión o el análisis predictivo se apoya con los pronósticos del tipo cualitativos o cuantitativos. Se observa que, un buen pronóstico es aquel que combina las diferentes técnicas cualitativas y cuantitativas, el buen juicio, la experiencia, el sentido común y la intuición, con un permanente seguimiento a los resultados para calibrar y evaluar la efectividad de los modelos. Dichas técnicas, usadas conjuntamente, brindan a la empresas el soporte necesario para la planificación de decisiones a corto, mediano y largo plazo. Así, el objetivo central de los pronósticos debe ser reducir el riesgo en la toma de decisiones, como un componente de planificación estratégica (Cadena Lozano, 2016, p. 24).

En el ámbito de la planificación estratégica, es fundamental distinguir entre los conceptos de predicción y pronóstico, ya que, aunque suelen utilizarse como sinónimos, poseen matices que influyen directamente en el enfoque metodológico de los modelos de estimación de demanda. Según lo expuesto por Álvarez (1997, como se citó en Cadena Lozano, 2016), la predicción se refiere al anuncio de eventos futuros mediante revelación, ciencia o conjetura, lo que implica una afirmación anticipada sobre lo que ocurrirá, basada en algún tipo de certeza o inferencia. En cambio, el pronóstico se fundamenta en el análisis de indicios observables, permitiendo al especialista formular juicios sobre la evolución futura de una empresa a partir de señales detectadas en variables que reflejan su gestión.

Esta distinción es clave para comprender el papel de los modelos de inteligencia artificial en la estimación de demanda. Mientras que la predicción puede asociarse con modelos deterministas o altamente automatizados, el pronóstico incorpora elementos de juicio experto, interpretación contextual y ajuste continuo. En consecuencia, los modelos más robustos combinan técnicas cuantitativas con criterios cualitativos, integrando datos históricos,

experiencia sectorial y análisis de entorno competitivo para generar estimaciones más precisas y adaptativas (Cadena Lozano, 2016, p. 24).

En el análisis de modelos de estimación de demanda, es común encontrar los términos predicción y previsión utilizados de forma intercambiable. Esta equivalencia conceptual ha sido respaldada por diversos autores citados por Cadena Lozano (2016), quienes coinciden en que ambos términos pueden referirse al mismo proceso de anticipación de eventos futuros basado en datos y teorías. Bunge (2000, como se citó en Cadena Lozano, 2016), por ejemplo, considera que la predicción científica es una forma de previsión sustentada en fundamentos teóricos y evidencia empírica, lo que refuerza su carácter metodológico y sistemático. En la misma línea, Courtney (2002, como se citó en Cadena Lozano, 2016) sostiene que la previsión, entendida como una visión precisa del futuro, es esencial para generar predicciones confiables y tomar decisiones estratégicas acertadas.

Además, Wilson y Keating (1996, como se citó en Cadena Lozano, 2016) aportan una definición operativa al señalar que las previsiones constituyen estimaciones numéricas proyectadas hacia un período futuro, las cuales pueden lograrse con un nivel determinado de soporte técnico o informativo. Esta perspectiva cuantitativa se alinea con los enfoques actuales de inteligencia artificial, donde los modelos predictivos se construyen sobre bases estadísticas, algoritmos de aprendizaje automático y simulaciones de escenarios. En conjunto, estas definiciones permiten afirmar que, en el contexto empresarial y técnico, la predicción y la previsión son conceptos funcionalmente equivalentes, ambos orientados a reducir la incertidumbre y mejorar la toma de decisiones (Cadena Lozano, 2016, pp. 25).

Como plantea Cadena Lozano (2016), sobre las diferencias de entre las definiciones de los autores mencionados de los conceptos de previsión, predicción y pronóstico se definen estos y otros conceptos para contextualizar la investigación:

Previsión

Una definición clásica y académicamente reconocida es la de Agustín Reyes Ponce (Reyes Ponce, 2004), quien plantea que:

[...] la previsión es el elemento de la administración en el que, con base en las condiciones futuras en que una empresa habrá de encontrarse, reveladas por una investigación técnica, se determinan los principales cursos de acción que nos permitirán realizar los objetivos de la empresa. (p. 11)

Predicción

“La predicción puede apoyarse en la intuición o la experiencia, sin requerir necesariamente un modelo formal” (Cifuentes, 2021, p. 5).

Pronóstico

“El pronóstico constituye una herramienta técnica que permite estimar el comportamiento futuro de variables específicas —como la demanda— mediante el uso de modelos matemáticos o estadísticos” (Cifuentes, 2021, p. 5).

Demanda

Según Mankiw (2004):

La demanda es la cantidad de productos o servicios que los consumidores están dispuestos a adquirir en un mercado determinado, durante un periodo específico, y bajo ciertas condiciones de precio. Esta cantidad depende de factores como el ingreso del consumidor, el precio del producto, el precio de bienes relacionados, las preferencias del consumidor y las expectativas sobre el futuro. Comprender la demanda permite a las empresas planificar su producción, distribución y estrategias comerciales de manera eficiente. (p. 78)

Precio

Según Echeverría Ríos et al. (2021):

El precio es la cantidad de dinero que los consumidores deben pagar para adquirir un producto o servicio. Su determinación está influida por múltiples factores, entre ellos, los costos de producción, la demanda del mercado, la competencia, los objetivos de la empresa y las percepciones del consumidor. El precio cumple funciones económicas, estratégicas y psicológicas, siendo una variable clave en la toma de decisiones comerciales y en la configuración del posicionamiento de marca. (p. 4)

Estacionalidad de un producto o servicio

El análisis de los ciclos comerciales exige comprender cómo diversos factores externos, climáticos e institucionales alteran el comportamiento del consumidor de forma cíclica y predecible a lo largo del año. Según Vega Raba (2023):

La estacionalidad se refiere a esas fluctuaciones o patrones sistemáticos y recurrentes durante un determinado periodo de tiempo. Este concepto surgió durante el siglo XX en base a estudios climatológicos y, posteriormente, empezó a ser estudiado en el campo económico, social, turístico, etc. En lo que concierne a los mercados, la estacionalidad se puede definir como aquellas variaciones predecibles en la demanda que se repiten durante periodos fijos, normalmente semanas, meses o años. Estas variaciones suelen estar vinculadas a factores como las condiciones meteorológicas, las tradiciones culturales, los días festivos y los calendarios institucionales. (p. 6)

Competencia

De acuerdo con Kotler & Keller (2012):

La competencia es la situación en la que dos o más empresas ofrecen productos o servicios similares en un mismo mercado, lo que obliga a cada una a mejorar sus procesos, precios, calidad y estrategias de comercialización para captar y mantener clientes. Esta dinámica impulsa la innovación, regula los precios y mejora la eficiencia, pero también puede generar presiones económicas y estratégicas que afectan la rentabilidad y sostenibilidad de las organizaciones. (p. 158)

Inteligencia artificial

Reier Forradellas y Nañez Alonso (2025) presentan diversas definiciones sobre lo que puede considerarse inteligencia artificial. No obstante, para efectos de este análisis, se tomará como referencia la definición establecida por Comisión Europea. (s. f.), que describe un sistema de inteligencia artificial como:

Un sistema basado en una máquina que está diseñado para funcionar con distintos niveles de autonomía y que puede mostrar capacidad de adaptación tras el despliegue, y que, para objetivos explícitos o implícitos, infiere en la información de entrada que recibe la manera de generar resultados de salida como predicciones, contenidos, recomendaciones o decisiones, que pueden influir en entornos físicos o virtuales.

Métodos para la predicción de la demanda

La predicción se apoya de los pronósticos para poder predecir el comportamiento de una variable.

En el ámbito organizacional, los pronósticos constituyen un componente esencial para la toma de decisiones estratégicas y operativas. Según Chase & Jacobs (2009), el pronóstico no solo


sustenta la planificación corporativa a largo plazo, sino que también se convierte en una herramienta clave en áreas funcionales como finanzas, contabilidad, *marketing* y operaciones. En finanzas, permite elaborar presupuestos y establecer mecanismos de control de costos; en *marketing*, orienta la planificación de nuevos productos, la gestión del equipo comercial y otras decisiones críticas. Asimismo, en producción y operaciones, los pronósticos facilitan la toma de decisiones periódicas relacionadas con la selección de procesos, la planificación de capacidades y la distribución de instalaciones, además de apoyar decisiones continuas sobre programación, inventarios y planificación de la producción.

La demanda de productos o servicios puede clasificarse en seis componentes: demanda promedio para el período, tendencia, elemento estacional, elementos cíclicos, variación aleatoria y autorrelación (Chase & Jacobs, 2019).

En la Figura 1, se presenta la estadística de como se ha comportado la demanda en un lapso de cuatro años. En ella, se pueden identificar la demanda promedio, la tendencia después de suavizar la curva, y, queda para el análisis, identificar la estacionalidad, los elementos cíclicos, la variación aleatoria y la autocorrelación. Para el caso de los pronósticos, estos pueden definirse como cualitativos y cuantitativos.

Figura 1

Gráfico para demostrar la tendencia,
demanda promedio de un estadístico de cuatro años




Nota. Imagen tomada y modificada de Jacobs & Chase (2019).

Según la Figura 1, los *factores cíclicos* pueden provenir de sucesos como eventos políticos, guerras, condiciones económicas o presiones sociológicas. Se pueden identificar cómo la curva senoidal va tomando la demanda en el transcurso del tiempo (trazo color rojo). El *elemento estacional* es el patrón de variación que se repite de forma regular en intervalos de tiempo específicos, como semanas, meses o trimestres, debido a factores cíclicos y previsibles. Las *variaciones aleatorias*, surgen después de analizar los resultados y no tener explicaciones del incremento o caída de la demanda. La *autocorrelación*, identifica el comportamiento de la variable en el transcurso del tiempo.

Las líneas de tendencia suelen constituir el punto de partida en la elaboración de un pronóstico. Posteriormente, dichas líneas se ajustan considerando los efectos estacionales, los factores cíclicos y cualquier otro acontecimiento previsto que pueda incidir en el resultado final.

En la Figura 2, se observan las tendencias más comunes al momento de realizar un pronóstico. Entre las tendencias se pueden encontrar del tipo lineal, donde existe un incremento uniforme en el tiempo. También, las curvas tipo “S” que pronóstica la tendencia de crecimiento o reducción de un producto o servicio en su etapa de madurez. Este tipo de curva (S), va a ocurrir cuando se desea saturar el mercado y capturar la mayor participación. Las curvas exponenciales se presentan cuando un producto o servicio tiene un crecimiento explosivo; siempre será necesario analizar la tendencia del crecimiento para evitar picos temporales. Una tendencia asintótica empieza con el crecimiento más alto de la demanda en un principio, pero después se reduce.

Figura 2
Tipos de tendencias



Nota. Imagen tomada y modificada de Chase & Jacobs (2019)

Al momento de realizar un pronóstico, se debe seleccionar el apropiado para la organización, contar con una fuente de datos confiables y considerar las variables que se pretenden relacionar.

Tradicionalmente los modelos de pronósticos pueden clasificarse según como se muestran en la Tabla 1.

Tabla 1
Clasificación de los modelos de pronósticos

Métodos cualitativos		
Se basan en estimados y opiniones, el conocimiento del área y la experiencia son la base fundamental para desarrollar la predicción.		
Métodos cuantitativos		
Son basados en información numérica y se relacionan con fundamentos matemáticos y/o estadísticos. Pueden clasificarse en tres tipos: series de tiempo, métodos causales y los modelos de simulación.		
Series de tiempo	Métodos causales	Modelos de simulación
Utiliza información relacionada con la demanda pasada para predecir la demanda futura.	Aplica la regresión lineal, relacionando un factor subyacente en el ambiente para predecir la demanda.	Son modelos asistidos casi siempre por computadoras y puede predecir escenarios sobre la manipulación de variables.

Nota. Adaptado de *La administración de la demanda y los modelos de pronóstico* (Cifuentes, 2021).

Los métodos cualitativos se desarrollan sobre juicios del conocimiento y la experiencia. Se recopilan opiniones y estimaciones de expertos, consumidores bajo un perfil en específico por medio de sesiones y, en algunas ocasiones, interacción con el producto o servicio. En la Tabla 2, se presentan los métodos de pronósticos cualitativos más utilizados.

Tabla 2
Clasificación de los modelos de pronósticos cualitativos

Métodos cualitativos		
Se basan en estimados y opiniones, el conocimiento del área y la experiencia son la base fundamental para desarrollar la predicción.		
Técnicas acumulativas	Investigación de mercados	Grupos de consenso
Deriva un pronóstico a través de la compilación de las entradas de aquellos que se encuentran al final de la jerarquía y que tratan con lo que se pronostica.	Muy utilizado para nuevos productos; aplica herramientas como encuestas, entrevistas, degustaciones, con el fin de comprobar hipótesis acerca de la potencialidad del producto o servicio. Es excelente para poder obtener una perspectiva de un rango del precio a pagar por el producto o servicio.	Analiza la interacción de ejecutivos, vendedores o clientes fieles y potenciales con la interacción del producto o servicio. Es conocido como focus groups (grupos focales).
Analogía histórica	Método de Delfos	
Toma un artículo similar y realiza predicciones para un producto nuevo.	Es un proceso iterativo y estructurado en el que se recopilan opiniones de expertos mediante cuestionarios sucesivos. Tras varias iteraciones, se obtiene una predicción o conclusión más confiable.	

Nota. Adaptado de La administración de la demanda y los modelos de pronóstico (Chase & Jacobs, 2009).

Los métodos de pronósticos que se clasifican dentro de los *análisis de series de tiempo*, están bajo la idea de que el historial de los eventos a través del tiempo se puede utilizar para proyectar el futuro. En la Tabla 3, se presentan los métodos utilizados en el análisis de series de tiempo.

Los métodos de *pronósticos causales*, permite combinar variables entre sí, es decir, la demanda puede ser predicha bajo el supuesto de cómo se comportaría al ser afectada por una o dos variables. Por ejemplo, cómo se comportaría la predicción de la demanda, al variar el precio, la estacionalidad y la competencia. En la Tabla 4, se pueden observar los métodos de pronósticos causales.

El método que mejor se aplica a la industria de la proyección de la demanda de consumo es el método causal de regresión múltiple y los modelos de simulación. El método de regresión permite cuantificar cuánto cambia la demanda, si varía el precio o si un competidor baja su tarifa, y la simulación permite crear escenarios *qué pasaría si* (ejemplo: si el competidor baja 10 % su precio, cómo se movería tu demanda).

Tabla 3

Clasificación de los métodos de análisis de series de tiempo

Métodos de análisis de series de tiempo		
El historial de los eventos a través del tiempo se puede utilizar para proyectar el futuro.		
Promedio móvil simple	Promedio móvil ponderado	Suavización exponencial
Se calcula el promedio de un periodo que contiene varios puntos de datos dividiendo la suma de los valores de los puntos entre el número de estos. Por lo tanto, cada uno tiene la misma influencia.	Es similar al promedio móvil simple, con la diferencia que, algunas variables, pueden tener una ponderación especial al analizar los resultados.	Los puntos de datos recientes se ponderan más y la ponderación sufre una reducción exponencial conforme los datos se vuelven más antiguos.
Análisis de regresión	Técnica Box Jenkins	Series de tiempo Shiskin (X-11)
Ajusta una recta a los datos pasados, casi siempre en relación con el valor de los datos. La técnica de ajuste más común es la de los mínimos cuadrados.	Relaciona una clase de modelos estadísticos con los datos y ajusta el modelo con las series de tiempo, utilizando distribuciones bayesianas posteriores.	Un método efectivo para dividir una serie temporal en temporadas, tendencias e irregular. Necesita un historial por lo menos de 3 años
		Proyecciones de tendencias
		Ajusta una recta matemática de tendencias a los puntos de datos y la proyecta en el futuro

Nota. Adaptado de La administración de la demanda y los modelos de pronóstico (Chase & Jacobs, 2009).

Tabla 4
Clasificación de los métodos de pronósticos causales

Métodos de pronósticos causales		
Permite combinar variables entre sí.		
Análisis de regresión	Modelos econométricos	Modelos de entrada/salida
El método puede proyectar, considerando bajo varias variables, bajo ocurrencia de eventos.	Utilizado mucho en las ciencias económicas mediante una serie de ecuaciones interdependientes.	Indica los cambios en las ventas que una industria productora puede esperar debido a los cambios en las compras por parte de otra industria.
Principales indicadores		
Predice considerando como un indicador principal puede afectar la demanda; por ejemplo, cómo el incremento del combustible afecta el precio de un producto o servicio.		

Nota. Adaptado de La administración de la demanda y los modelos de pronóstico (Chase & Jacobs, 2009).

Métodos para la predicción de la demanda considerando más de una variable: Método de regresión múltiple

Según Mario F. Triola: “La estadística inferencial consiste en métodos que permiten tomar decisiones o realizar inferencias acerca de una población basándose en información obtenida de una muestra” (Triola, 2018, p. 6).

También, permite trabajar una variable a nivel de intervalo o razón, comprender la relación de dos o más variables mediante ecuaciones. La relación de una variable en relación de la otra variable se le llama *regresión lineal* y una variable en relación con otras variables se le llama *regresión múltiple*.

Al enfocarnos a la regresión múltiple, este tipo de regresión se presenta cuando dos o más variables independientes influyen sobre una variable dependiente. Las técnicas de regresión múltiple parten de K+1 variables cuantitativas y puede expresarse con la Ecuación 1.

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3$$

Ecuación 1

La Ecuación 1, se puede ampliar para cualquier número “m” de variables independientes:

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_mX_m$$

Ecuación 2

Para encontrar las incógnitas de la ecuación 2 se hace uso de las matrices inversas y se logra obtener las siguientes ecuaciones para simultanear (se presenta la solución para un análisis de tres variables, en el Anexo 2. Se presenta cómo se puede construir el modelo de resolución para m variables).

$$\sum Y = na + b_1 \sum X_1 + b_2 \sum X_2 + b_3 \sum X_3$$

Ecuación 3

$$\sum YX_1 = a \sum X_1 + b_1 \sum X_1^2 + b_2 \sum X_1X_2 + b_3 \sum X_1X_3$$

Ecuación 4

$$\sum YX_2 = a \sum X_2 + b_1 \sum X_1X_2 + b_2 \sum X_2^2 + b_3 \sum X_2X_3$$

Ecuación 5

$$\sum YX_3 = a \sum X_3 + b_1 \sum X_1X_3 + b_2 \sum X_2X_3 + b_3 \sum X_3^2$$

Ecuación 6

El error estándar de la regresión múltiple (S_{xy}), es una medida de dispersión, la estimación se hace más precisa conforme el grado de dispersión alrededor del plano de regresión se hace más pequeño. Para medirla se utiliza la Ecuación 7.

$$S_{xy} = \sqrt{\frac{\sum (Y - \hat{Y})^2}{n - m - 1}}$$

Ecuación 7

Donde:

Y = Valores observados en la muestra

$\hat{Y}$ = Valores estimados a partir de regresión

n = Números de datos

m = Números de variables independientes

El coeficiente de determinación múltiple (r^2) mide la tasa X_1 , X_2 y X_3 , porcentual de los cambios de y que pueden ser explicados por simultáneamente.

$$r^2 = \frac{SC_{regresión}}{SC_{Total}}$$

Ecuación 8

Ejercicio de aplicación de regresión múltiple

Se desarrolla un ejercicio donde se determinará la cantidad de unidades a demandar, considerando el precio del producto, precio del producto de la competencia y la estacionalidad.

Planteamiento del ejercicio

Se pretende pronosticar la demanda de un producto, pero esta debe encontrarse en función del comportamiento del precio propio del producto, el precio del competidor más cercano y un factor de estacionalidad. En la Tabla 5, se presenta el histórico de ventas en unidades del producto.

Tabla 5
 Histórico de ventas en unidades

Mes	Demanda (unidades)	Precio (US\$)	Precio de la competencia (US\$)	Grado de estacionalidad
Ene	1,200	10.00	10.50	0.95
Feb	1,150	10.20	10.40	0.95
Mar	1,300	9.80	10.60	1.00
Abr	1,400	9.50	10.70	1.05
May	1,500	9.30	10.80	1.10
Jun	1,450	9.40	10.90	1.10
Jul	1,350	9.70	10.60	1.05
Ago	1,320	9.80	10.50	1.00
Sep	1,250	10.10	10.30	0.95
Oct	1,280	10.00	10.40	1.00
Nov	1,380	9.60	10.70	1.05
Dic	1,600	9.20	11.00	1.20

Solución

Identificación de variables

Se identifican las variables a utilizar para sustituir en las ecuaciones.

Y = Demanda del producto a pronosticar (Unidades)

X_1 = Precio propio del producto (\$)

X_1 = Precio propio del producto (\$)

X_1 = Precio propio del producto (\$)

X_1 = Precio propio del producto (\$)

Nota: La estacionalidad se analiza de forma mensual, se considera que es un momento donde la venta se incrementa, y es un índice numérico que tiene los siguientes rangos: $X_3=1$, neutral; $X_3>1$, estacionalidad alta; $X_3<1$, estacionalidad baja.

Determinación de los valores de las constantes

Tabla 6

Determinación de constantes

Y	X_1	X_2	X_3										
Mes	Demanda (unidades)	Precio (US \$)	Precio de la competencia (US \$)	Grado de estacionalidad	X_1X_2	X_1X_3	X_2X_3	X_1^2	X_2^2	X_3^2			
Ene	1,200	10.00	10.50	0.95	105.00	9.50	9.98	100.00	100.00	0.90			
Feb	1,150	10.20	10.40	0.95	106.08	9.69	9.88	104.04	104.04	0.90			
Mar	1,300	9.80	10.60	1.00	103.88	9.80	10.60	96.04	96.04	1.00			
Abr	1,400	9.50	10.70	1.05	101.65	9.98	11.24	90.25	90.25	1.10			
May	1,500	9.30	10.80	1.10	100.44	10.23	11.88	86.49	86.49	1.21			
Jun	1,450	9.40	10.90	1.10	102.46	10.34	11.99	88.36	88.36	1.21			
Jul	1,350	9.70	10.60	1.05	102.82	10.19	11.13	94.09	94.09	1.10			
Ago	1,320	9.80	10.50	1.00	102.90	9.80	10.50	96.04	96.04	1.00			
Sep	1,250	10.10	10.30	0.95	104.03	9.60	9.79	102.01	102.01	0.90			
Oct	1,280	10.00	10.40	1.00	104.00	10.00	10.40	100.00	100.00	1.00			
Nov	1,380	9.60	10.70	1.05	102.72	10.08	11.24	92.16	92.16	1.10			
Dic	1,600	9.20	11.00	1.20	101.20	11.04	13.20	84.64	84.64	1.44			
Total	16,180	116.60	127.40	12.40	1,237.18	120.24	131.81	1,134.12	1,134.12	12.88			

Tabla 7
Determinación de constantes

Mes	Demanda (unidades)	Precio (US\$)	Precio de la competencia (US\$)	X_1Y	X_2Y	X_3Y
Ene	1,200	10.00	10.50	12,000.00	12,600.00	1,140.00
Feb	1,150	10.20	10.40	11,730.00	11,960.00	1,092.50
Mar	1,300	9.80	10.60	12,740.00	13,780.00	1,300.00
Abr	1,400	9.50	10.70	13,300.00	14,980.00	1,470.00
May	1,500	9.30	10.80	13,950.00	16,200.00	1,650.00
Jun	1,450	9.40	10.90	13,630.00	15,805.00	1,595.00
Jul	1,350	9.70	10.60	13,095.00	14,310.00	1,417.50
Ago	1,320	9.80	10.50	12,936.00	13,860.00	1,320.00
Sep	1,250	10.10	10.30	12,625.00	12,875.00	1,187.50
Oct	1,280	10.00	10.40	12,800.00	13,312.00	1,280.00
Nov	1,380	9.60	10.70	13,248.00	14,766.00	1,449.00
Dic	1,600	9.20	11.00	14,720.00	17,600.00	1,920.00
Total	16,180	116.60	127.40	156,774.00	172,048.00	16,821.50

Sustitución de los valores en las ecuaciones

Ecuación principal

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3$$

Llamando a la ecuación 2, para m variables se tiene:

Ecuación complementarias

Invocando las ecuaciones de la 3 a la seis y sustituyendo las constantes identificadas en la Tabla 6 se puede obtener lo siguiente:

$$16,180 = 12a + 116.60 b_1 + 127.40 b_2 + 12.40 b_3$$

$$156,774 = a 116.60 + 1,134.12 b_1 + 1,237.18 b_2 + 120.24 b_3$$

$$172,048 = 127.40 a + 1,237.18 b_1 + 1,353.06 b_2 + 131.81 b_3$$

$$16,821.50 = 12.40 a + 120.24 b_1 + 131.81 b_2 + 12.88 b_3$$

Simultaneo de ecuaciones para encontrar las variables

Para poder determinar el valor de las variables, se puede utilizar el simultaneo de ecuaciones con 4 variables o por medio de matriz inversa¹.

El resultado final es el siguiente:

$$Y = 6,251.49 - 314.68 b_1 - 283.05 b_2 + 1,122.21 b_3$$

$$Y = 6,251.49 (u) - 314.68(u) b_1 \left(\frac{\$}{u}\right) - 283.05(u) b_2 \left(\frac{\$}{u}\right) + 1,122.21(u) b_3 \left(\frac{\$}{u}\right)$$

Donde las variables están expresadas en unidades (u) y las variables en dólares USD por unidades (\$/u)

La ecuación obtenida se puede interpretar de la siguiente forma:

- **Intercepto (6251.49):** nivel base de la demanda.
- **X₁ (-314.68):** cada aumento de 1 dólar en el precio propio reduce la demanda en 315 unidades.
- **X₂ (-283.05):** cada aumento de 1 dólar en el precio del competidor reduce la demanda en 283 unidades (mercado sensible al nivel general de precios).
- **X₃ (+1,122.21):** un incremento de 0.1 en el índice estacional aumenta la demanda en 112 unidades. (1,122.21 * 0.10 = 112)

Al simular un período futuro bajo las siguientes condiciones, la demanda del producto podría ser:

¹ En el siguiente enlace se muestra un vídeo donde se puede aplicar el simultaneo por medio de matrices para un ejercicio de regresión múltiple <https://youtu.be/ZmNDRnmYaPc?si=zBucWDW1MOxBRxof>

- X_1 (Precio propio) = \$ 9.5 / unidad
- X_2 (Precio competencia) = \$ 10.8 / unidad
- X_3 (Factor de estacionalidad) = 1.10

Sustituyendo los valores en la ecuación encontrada:

$$Y = 6,251.49(u) - 314.68(u)\left(\frac{\$ 9.5}{\text{Unidad}}\right) - 283.05(u)\left(\frac{\$ 10.5}{u}\right) + 1,122.21(u)(1.10)$$

$$Y = 1,439 \text{ unidades}$$

Se puede interpretar el dato que, con una estacionalidad alta y un incremento en el precio propio, versus una disminución en el precio del competidor, la cantidad a vender es de 1,439 unidades, es decir, una reducción 161 unidades respecto al último período.

El error estándar de la regresión múltiple (S_{xy}), es de 13.06, es decir, el modelo se equivoca en promedio por 13 unidades de demanda, lo cual es mínimo considerando que la demanda oscila entre 1,426 y 1,452.

El coeficiente de determinación múltiple (r^2), muestra lo bien que se ajusta un modelo de regresión a un conjunto de datos, es decir, indica el porcentaje explicado por el modelo de regresión, Por lo tanto, cuanto mayor sea el coeficiente de determinación, mejor será el modelo de regresión. Para el caso del ejercicio es del 98.86 %, demostrando un nivel de confianza bastante alto.

Fundamentos de la inteligencia artificial y el aprendizaje automático (*machine learning*)

Fundamentos de la inteligencia artificial

Según Gallegos et al. (2014), los que desean desarrollar inteligencia artificial deben haber obtenido como conocimientos previos el razonamiento lógico, programación de aplicaciones, fundamentos

matemáticos y estadísticos, ya que estos conocimientos son la base para el desarrollo de modelos matemáticos que permiten llegar a la solución de un problema, así como la modelación de sistemas que resuelvan problemas como si lo hiciera un humano.

Según el objeto y la forma en que trabaja el sistema, la inteligencia artificial puede poseer una clasificación de forma independiente. La inteligencia puede ser clasificada como: “sistemas que piensan como humanos, sistemas que actúan como humanos, sistemas que piensan racionalmente, sistemas actuantes racionales” (Gallegos et al. 2014).

Figura 3
Tópicos de la Inteligencia Artificial



Nota. Imagen elaborada a partir de Gallegos et al. (2014).

Las áreas específicas en las que pueden trabajarse por medio de la inteligencia artificial cuentan con herramientas y/o técnicas propias para lograr sus objetivos (Gallegos et al. 2014).

Figura 4
Tipos de IA



Nota. Imagen elaborada a partir de Gallegos et al. (2014)

La inteligencia artificial ha atravesado diversos ciclos de auge y declive, marcados tanto por el entusiasmo excesivo y la pérdida de apoyos, como por la aparición de enfoques innovadores y el perfeccionamiento de los existentes. Debido a sus vínculos con disciplinas como la medicina, la psicología, la biología y la filosofía, ha enfrentado críticas y oposición desde sus orígenes; no obstante, el interés sostenido de ciertos grupos, permitió que se consolidara como un campo relevante para la investigación científica (Gallegos et al., 2014).

La IA se concibe como el campo de estudio que busca diseñar sistemas capaces de realizar tareas que requieren inteligencia humana, como el razonamiento, la percepción, la planificación y el aprendizaje. Su alcance incluye desde algoritmos básicos hasta sistemas complejos de redes neuronales profundas (Russell & Norvig, 2021).

- Las aplicaciones de IA tienen las bases teóricas sobre las ciencias de:
- Lógica y matemáticas. La IA se apoya en la lógica proposicional y matemática para la representación del conocimiento y la inferencia (Nilsson, 1998).
- Estadística y probabilidad. Permiten modelar la incertidumbre y tomar decisiones en entornos dinámicos (Pearl, 1988).
- Neurociencia y cognición. Inspiran modelos como las redes neuronales artificiales, basadas en el funcionamiento del cerebro humano (Haykin, 2009).

La IA enfrenta desafíos relacionados con la transparencia, la facilidad para explicar los modelos, la equidad en la toma de decisiones y la responsabilidad social (Floridi & Cows, 2019).

Fundamentos del aprendizaje automático (*machine learning*)

El aprendizaje automático (*machine learning* o ML) es un subcampo de la inteligencia artificial que se centra en el desarrollo de algoritmos capaces de aprender patrones a partir de datos y mejorar su desempeño sin necesidad de programación explícita (Mitchell, 1997).

Su propósito es que los sistemas adapten su comportamiento en función de la experiencia, lo que lo convierte en una herramienta esencial en la era del *big data*.

El ML se fundamenta en la estadística, la teoría de la probabilidad y la optimización matemática, que permiten modelar relaciones entre variables y predecir resultados (Bishop, 2006). Además, se nutre de la informática y la neurociencia, especialmente en el desarrollo de redes neuronales artificiales (Haykin, 2009). Entre los principales desafíos se encuentran la interpretabilidad de los modelos, la calidad de los datos y las implicaciones éticas relacionadas con la equidad y la privacidad (Domingos, 2015).

Figura 5

Proceso de modelado de *machine learning*



Figura 6

Aplicaciones de *machine learning*



CAPÍTULO III

METODOLOGÍA

En este capítulo se expone el desarrollo de la investigación. El propósito central es ofrecer una guía precisa sobre el método aplicado y destacar su relevancia en la obtención de los resultados alcanzados.

Muñoz (2011) sostiene que la investigación constituye un proceso metódico y especializado, estructurado en fases precisas, definidas y fundamentadas, las cuales deben adaptarse a las condiciones y particularidades del tema abordado. En esta misma línea, Hernández Sampieri & Mendoza (2018) distingue dos enfoques principales para el desarrollo de investigaciones: el cuantitativo y el cualitativo. Ambos enfoques se caracterizan por la aplicación de procedimientos rigurosos, sistemáticos y empíricos, orientados a la generación de conocimiento válido y confiable, lo que evidencia su complementariedad en la construcción de marcos teóricos y prácticos sólidos.

El enfoque cuantitativo se emplea principalmente para la evaluación de hipótesis, las cuales pueden ser sometidas a pruebas exhaustivas y analizadas mediante procedimientos matemáticos propios de los métodos de investigación estandarizados.

Por su parte, el enfoque cualitativo se orienta a la comprensión profunda de los fenómenos, explorándolos desde la perspectiva de los participantes en su contexto natural. Este enfoque resulta pertinente cuando el objetivo es examinar cómo los individuos perciben y experimentan los fenómenos que los rodean, permitiendo indagar en sus puntos de vista, interpretaciones y significados.

La presente investigación se define formalmente como un estudio de enfoque cualitativo. De acuerdo con Hernández

Sampieri & Mendoza (2018), los estudios cualitativos se centran en la comprensión e interpretación de significados a través de datos no numéricos. En este sentido, la investigación adopta una metodología de corte bibliográfico y documental, donde la recolección de información se realiza mediante el análisis crítico, sistemático e interpretativo de literatura científica especializada (libros, revistas, artículos y tesis), constituyendo a los textos como la fuente primaria para dar respuesta a los objetivos planteados.

En la Figura 7 se presenta el esquema de la investigación

Figura 7

Esquema de la investigación



Técnicas, instrumentos, recolección y Procedimientos de formación

Las técnicas utilizadas para procesar la información de libros, revistas, artículos o tesis en la investigación son los siguientes:

1. **Análisis de contenido.** Se identificaron los temas claves en la literatura. Se analizó la literatura científica para encontrar hallazgos significativos que se apliquen a la investigación.
2. **Hermenéutica.** Se hizo un análisis profundo de textos con contexto científico. Se ejecutó una revisión crítica y se encontró una interpretación propia de los textos consultados.

Para validar científicamente la recolección documental, se definieron tres criterios de elegibilidad e inclusión, aplicados a la bibliografía:

1. **Criterio de pertinencia temática:** encontrar textos que proporcione información de una investigación de las dimensiones del problema: modelado de demanda, inteligencia artificial / aprendizaje automático, y variables macroeconómicas/operativas (precio, estacionalidad, gestión de inventarios).
2. **Criterio de textos con alto nivel de calidad antes de ser publicados:** identificación y análisis de textos que tenga un filtro estricto de control de calidad antes de ser publicados (artículos en IOP Publishing, Harvard Data Science Review, RECAI), visitar repositorios institucionales de alta exigencia académica (Universidad de Chile, Universidad de Cantabria, Universidad Austral de Chile) y textos de editoriales de referencia (Springer, McGraw-Hill, Pearson).
3. **Criterio de coexistencia cronológica (evolutiva vs. frontera):** encontrar un equilibrio metodológico intencional entre las fuentes base, utilizando textos clásicos que presente teorías y modelos tradicionales, que siguen siendo base obligatorio

de la disciplina a pesar de los años (teorías fundacionales de administración y algoritmos que no pierden vigencia) y producción científica más reciente (producción científica entre 2017 y 2025 para capturar el estado del arte en inteligencia artificial y transformación digital).

Propuesta para el desarrollo de modelos de IA para la predicción de la demanda de productos considerando las variables de precio, estacionalidad y competencia

Son muchas las aplicaciones que ya poseen la IA como una herramienta de mejora en las predicciones de la demanda, pero el objetivo de la investigación es encontrar una aplicación por medio de IA que permita predecir con más de una variable dentro del modelo.

En el mercado pueden encontrarse herramientas especializadas como Amazon Forecast, Vertex AI, GluonTS y Prophet que facilitan este tipo de pronósticos, adaptándose a distintos sectores y necesidades operativas. Realizando una investigación a detalle de las herramientas recomendadas y evaluando características como la capacidad de manejar grandes cantidades de datos, crear prototipos, perfeccionar modelos, aprendizaje *machine learning*, se pueden destacar:

AMAZON Forecast

Utiliza series temporales y *machine learning* para presentar resultados más precisos, Ideal para empresas que buscan escalabilidad y modelos probabilísticos listos para producción. Útil para *retail*, logística y *supply chain*.

Google Vertex AI

Esta aplicación tiene el soporte de Google, se relaciona con Gemini, que es la IA de Google. Puede utilizar imágenes, video o código

para solventar los casos. Permite construir, entrenar y desplegar modelos de forecasting integrados con datos en la nube. Tiene buen rendimiento para generar pronósticos de forma continua y secuencia que analizan grandes cantidades de datos.

GluonTS

GluonTS (de AWS) es un toolkit para modelos probabilísticos avanzados en forecasting, pensado para producción. Permite modelos basados en *deep learning* y evaluación robusta de incertidumbre, clave para decisiones operativas. Recomendado para implementaciones con foco en *forecasting* probabilístico.

Power Apps

Esta aplicación se vuelve más accesible para los responsables de pronosticar dentro de las organizaciones. Fue lanzado oficialmente en octubre de 2016, como parte de la Microsoft Power Platform, junto con Power BI y posteriormente Power Automate. Es un conjunto de aplicaciones, servicios y conectores, junto con una plataforma de datos (Microsoft Dataverse), que ofrece un entorno de desarrollo ágil para crear soluciones empresariales sin necesidad de conocimientos avanzados de programación.

Pasos para construir un modelo de pronóstico de la demanda con IA

Una definición clara del objetivo y horizonte del pronóstico alinea el proceso con la administración de la demanda y la planificación agregada, facilitando decisiones tácticas y operativas consistentes (Dorado González & Velásquez Robayo, 2020; Altamirano Tapias & Marín Peralta, 2021).

En aplicaciones empresariales, especificar producto, canal y periodo evita sesgos y mejora la trazabilidad de decisiones de inventario y capacidad (Dorado González & Velásquez Robayo, 2020).

Se propone los siguientes pasos al momento de querer implementar un modelo de predicción por medio de la IA:

Recolección y preparación de datos

En esta parte deben realizarse una recolección y preparación de los datos que permita darle una calidad a los datos. Variables internas (ventas, precios, promociones, quiebres) y externas (estacionalidad, calendario, clima, eventos) condiciona la validez del pronóstico y su utilidad en operación. El incorporar variables externas al modelo mejora el desempeño de los resultados (Dorado González & Velásquez Robayo, 2020).

Prácticas de preprocesamiento como depuración de atípicos, imputación y normalización son estándar, y la ingeniería de características temporales (*lags*, ventanas) es crítica al trabajar con redes neuronales (Altamirano Tapias & Marín Peralta, 2021).

Identificación del modelo de pronóstico

Identificar el modelo que mejor se adapte al comportamiento de los datos es muy importante para poder crear un modelo por medio de IA. Uno de los modelos que mejor se apega cuando se trata de evaluar los resultados en función de dos o más variables, es el método de regresión múltiple.

Selección de técnicas de IA

Se deben elegir las aplicaciones que realizarán el desarrollo de las predicciones por medio de la IA.

Los modelos de series temporales, como ARIMA, son líneas base por su interpretabilidad y rapidez, mientras que enfoques de aprendizaje supervisado (regresión, árboles, *boosting*), capturan efectos no lineales y de promoción/precio. Los modelos híbridos combinan señal temporal y variables explicativas para robustez ante campañas y *shocks* (Dorado González & Velásquez Robayo, 2020).

Las redes neuronales recurrentes (LSTM) son adecuadas para dependencias de largo alcance y han demostrado errores bajos en escenarios reales de demanda con suficiente historial (Altamirano Tapias & Marín Peralta, 2021).

Entrenamiento y validación

La partición en entrenamiento, validación y prueba, junto con validación cruzada temporal (ventanas rodantes o expansivas), evita fuga de información y evalúa desempeño fuera de muestra (Dorado González & Velásquez Robayo, 2020).

Implementación en la operación

Reportes con descomposición de señales y alertas por desvíos de error mejoran la toma de decisiones y la transparencia metodológica (Duhalde Pérez, 2022).

Integrar el modelo con sistemas ERP/APS permite que el pronóstico alimente compras, planeación y reposición con cadencias alineadas al flujo de datos (Dorado González & Velásquez Robayo, 2020).

Monitoreo y mejora continua

La evolución de variables con nuevas fuentes (clima, calendario escolar, campañas digitales) y la retirada de irrelevantes es parte del ciclo de mejora en IA aplicada a demanda (Dorado González & Velásquez Robayo, 2020).

La gobernanza de datos, bitácoras y responsables asegura la trazabilidad y el alineamiento con procesos S&OP (Duhalde Pérez, 2022).

CAPÍTULO IV

RESULTADOS DE LA INVESTIGACIÓN

Conclusiones

- A lo largo del tiempo, las diferentes organizaciones siempre han buscado la forma de poder predecir los fenómenos que pueden afectar o hacer crecer la rentabilidad, por lo tanto, la práctica de la predicción se debe volver parte de la planeación estratégica.
- Los hallazgos del estudio de investigación permiten darnos cuenta de que los pronósticos poseen una sólida base científica al utilizar las matemáticas y la estadística, pero, aun así, no garantiza que el error de la predicción sea mínimo o eliminado. Además, se encontró que los modelos de pronóstico, entre más variables tienen que analizar se vuelven más complejos de resolver de forma tradicional; adicional, que hay que iterar enorme cantidades de datos para que la certeza sea aceptable. La incorporación de nuevos modelos de pronósticos, como lo es la regresión múltiple, permite analizar más de una variable, es decir, permite capturar relaciones no lineales y efectos temporales (tendencia, estacionalidad y ciclos), logrando errores bajos (y altos coeficientes de determinación como se demostró en el ejercicio de caso). Pero, es por medio de la inteligencia artificial que se comienzan a tener resultados más adaptados a la realidad, en menor tiempo o en tiempo real y sobre todo el hallazgo más importante que puede aprender del error para mejorar los resultados con cada iteración.
- La inteligencia artificial (IA) como hallazgo principal es un campo que está desarrollando sistemas que pueda resolver tareas de inteligencia humana, considerando el

razonamiento, la percepción, la planificación y sobre todo el aprendizaje. También, la IA no pierde la base científica de lógica y matemática; estadística y probabilidad; neurociencia y cognición.

- Se debe considerar que, antes de aplicar la IA como herramienta para un modelo de predicción, debe saberse elegir qué tipo de pronóstico (como herramienta de la predicción) se relaciona de mejor forma con lo que se pretende predecir, esto permitirá dar instrucciones correctas desde el inicio al motor de la IA y obtener resultados acordes a la realidad.
- El enfoque metodológico propuesto es aplicable y escalable: los pasos de recolección, elección de modelo, entrenamiento/validación y monitoreo continuo permiten trasladar el prototipo conceptual hacia entornos operativos (ERP/APS), aun cuando el trabajo delimita que no se implementará una aplicación informática.
- Plataformas que ya incorporan la IA como parte de la resolución de predicciones, pueden facilitar la integración de modelos estadísticos y el *machine learning* para pronósticos.

Recomendaciones

De la investigación realizada se recomienda lo siguiente:

- Se debe mantener una revisión ética y de riesgo del uso de IA. Muchas aplicaciones ocupan la opción de espiar medios de comunicación como celulares, visitas a páginas web, y redes sociales, para la captura de datos. Siempre debe existir una solicitud de permiso al consumidor de la captura de información por medio de los dispositivos o medios, para mantener el sentido humano. Además, el fin principal de la IA debe ser para efectos de proporcionar, cada vez, mejores productos o servicios con demandas más atinadas y no

promover otras situaciones que puedan generar riesgos a los consumidores en temas relacionado con la privacidad de los mismos.

- La variable competencia y estacionalidad siempre debe cuantificarse para poder ser aplicada en el modelo de la regresión múltiple.
- Existen modelos de pronósticos similares o diferenciadores a la regresión múltiple, los cuales pueden ser investigados con el fin de ir reduciendo la incertidumbre o el error en las predicciones.
- Factores que pueden ayudar al entrenamiento del modelo pueden ser el monitoreo del error (MAPE, MAE, r^2), políticas de calidad de datos, bitácoras y responsables; medir periódicamente el desempeño y activar alertas por desvíos para calibrar hiperparámetros y mejorar la trazabilidad de decisiones.
- Para una mejor comprensión del mercado se puede ampliar la gama de las variables que pueden afectar un pronóstico como pueden ser: promociones, quiebres de *stock*, campañas digitales y efectos macro (combustible, tipo de cambio).

REFERENCIAS

- Acevedo-Díaz, J. A., García-Carmona, A., Aragón-Méndez, M. M., & Oliva-Martínez, J. M. (2017). Modelos científicos: significado y papel en la práctica científica. *Revista Científica*, 30(3), 155-166. <https://doi.org/10.14483/23448350.12288>
- Adúriz Bravo, A., & Ariza, Y. (2014). Una caracterización semanticista de los modelos científicos para ciencia escolar. *Bio-grafía: Escritos sobre la Biología y su Enseñanza*, 7(13), 25-34. <https://doi.org/10.17227/20271034.vol.7num.13bio-grafia25.34>
- Altamirano Tapias, Á. F., & Marín Peralta, M. A. (2021). *Predicción de la demanda de un producto con redes neuronales*. Fundación Universitaria Los Libertadores. <https://repository.libertadores.edu.co/server/api/core/bitstreams/110a43cc-4a9a-426b-aaed-bd2378051626/content>
- Amazon Web Services. (s. f.). *Amazon Forecast algorithms*. AWS Documentation. <https://docs.aws.amazon.com/forecast/latest/dg/aws-forecast-choosing-recipes.html>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Brunnello, M., & Rocha Vargas, M. (2010/2011). *Modelado de procesos* [Material técnico, 1ra versión 2010; actualización 2011].
- Cadena Lozano, J. B. (2016). *Gestión del pronóstico estratégico: Una herramienta de planificación en las empresas*. Ecoe Ediciones.

- Chase, R. B., & Jacobs, F. R., (2009). *Administración de operaciones: Producción y cadena de suministro* (11.^a ed.). McGraw-Hill.
- Cifuentes, J. (2021). *La administración de la demanda y los modelos de pronóstico*. Universidad San Marcos. <https://repositorio.usam.ac.cr/xmlui/bitstream/handle/11506/1946/LEC%20PROD%200002%202021.pdf>
- Comisión Europea. (s. f.). *Artículo 3: Definiciones*. AI Act Service Desk. <https://ai-act-service-desk.ec.europa.eu/es/ai-act/article-3>
- Chopra, S., & Meindl, P. (2019). *Supply Chain Management: Strategy, Planning, and Operation* (7th ed.). Pearson Education.
- Dorado González, S., & Velásquez Robayo, V. (2020). *Pronóstico de demanda utilizando inteligencia artificial*. Universidad Icesi. <https://repository.icesi.edu.co/server/api/core/bitstreams/eb9f814c-1bc8-4040-aa52-4a8bf6737054/content>
- Domingos, P. (2015). *The master algorithm: How the quest for the ultimate learning machine will remake our world*. Basic Books.
- Duhalde Pérez, L. A. (2022). *Propuesta de modelo de predicción de la demanda de servicios y productos para TELSUR Grupo GTD*. Universidad Austral de Chile. <http://cybertesis.uach.cl/tesis/uach/2022/bmfcd869p/doc/bmfcd869p.pdf>
- Echeverría Ríos, O. M., Martínez Hernández, M., & López Hernández, I. (2021). Precio en mercadotecnia: Una revisión bibliográfica desde la percepción en Latinoamérica. *RECAI Revista de Estudios en Contaduría, Administración e Informática*, 10(29), 1-20. Recuperado de <https://www.redalyc.org/articulo.oa?id=637968300004>
- Fierro Torres, C. Á., Castillo Pérez, V. H., & Torres Saucedo, C. I. (2022). Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características. *Revista*

Iberoamericana para la Investigación y el Desarrollo Educativo, 12(24), e354. <https://doi.org/10.23913/ride.v12i24.1203>

Floridi, L., & Cowls, J. (2019). A unified framework of five principles for AI in society. *Harvard Data Science Review*, 1 (1). <https://doi.org/10.1162/99608f92.8cd550d1>

Gallegos, J. C. P., Torres, A., Quezada Aguilera, F. S., Silva Sprock, A., Martínez Flor, E. U., Casali, A., Scheihing, E., Túpac Valdivia, Y. J., Torres Soto, M. D., Ornelas Zapata, F. J., Hernández A., J. A., Zavala D., C., Vakhnia, N., & Pedreño, O. (2014). *Inteligencia artificial*. Alfaomega.

Giere, R. N. (2004). How Models Are Used to Represent Reality. *Philosophy of Science*, 71, 742-752. <https://doi.org/10.1086/425063>

Hernández Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Interamericana.

Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.

Kamaliah, K., Siregar, R. R. S., & Husein, A. M. (2017). Sales forecasting using support vector machine. *Journal of Physics: Conference Series*, 930 (1), Article 012002. <https://doi.org/10.1088/1742-6596/930/1/012002>

Kotler, P., & Keller, K. L. (2012). *Dirección de marketing* (14.ª ed.). México: Pearson Educación.

Mankiw, N. G. (2004). *Principios de economía* (3.ª ed.). Thomson.

Makridakis, S. G. (1993). *Pronósticos: Estrategia y planificación para el siglo XXI*. Ediciones Díaz de Santos. <https://www.editdiazdesantos.com/libros/makridakis-spyros-g-pronosticos-L03000370101.html>

Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.

Morozova, N. (s. f.). *SAP Integrated Business Planning (IBP): Everything you need to know*. TeamIdea Group. https://teamideagroup.com/blog/for_clients/sap-integrated-business-planning-Everything%20You%20Need%20To%20Know/

Muñoz Razo, C. (2011). *Cómo elaborar y asesorar una investigación de tesis* (2ª ed.). Pearson Educación.

Nilsson, N. J. (1998). *Artificial intelligence: A new synthesis*. Morgan Kaufmann.

Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. Morgan Kaufmann.

Ortiz Uribe, F. G. (2003). *Diccionario de metodología de la investigación científica* (p. 3). Limusa Noriega Editores. Enlace al PDF: biblioteca-digital.universidadcolumbia

Ortiz Uribe, F. (2003). *Diccionario de metodología de la investigación* (p.116). Limusa Noriega Editores.

Render, B., Heizer, J., & Munson, C. (2017). *Principios de administración de operaciones* (9.ª ed.). Pearson Educación.

Reier Forradellas, R., & Nañez Alonso, S. (2025). *Transformación digital y negocios inteligentes: La era de la inteligencia artificial*.

Reyes Ponce, A. (2004). *Administración moderna* (12.ª ed.). Grupo Editorial Patria.

Rojas, A. A. M. (2024). *Desarrollo de modelos de pronóstico de demanda con variables predictoras para mejorar la gestión de inventarios en una empresa de alimentos* [Memoria de título de Ingeniero Civil Industrial, Universidad de Chile]. Repositorio Académico de la Universidad de Chile. <https://repositorio.uchile.cl/handle/2250/204012>

Roldán, P. N., & Sevilla Arias, A. (10 de marzo de 2025). *Estadística: ¿Qué es y para qué sirve? Tipos y ejemplos*. Economipedia. <https://economipedia.com/definiciones/estadistica.html>

Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Triola, M. F. (2018). *Estadística* (12.^a ed.). Pearson Educación de México.

Vega Raba, J. (2023). *Análisis de la estacionalidad de los productos de Lupa supermercados* [Trabajo de fin de grado, Universidad de Cantabria]. Repositorio Institucional UCrea. <https://repositorio.unican.es/xmlui/handle/10902/39737>

Winsberg, E. (2010). *Science in the age of computer simulation*. University of Chicago Press.

YouTube. (2021, 23 de noviembre). *Regresión lineal múltiple | Ejercicio resuelto* [Video]. YouTube. <https://youtu.be/ZmNDRnmYaPc>

ANEXOS

Anexo 1

MAPE (Error de porcentaje medio absoluto)

El error de porcentaje medio absoluto (MAPE) se calcula utilizando el error absoluto de cada período dividido por los valores observados que son evidentes para ese período, para luego promediar dichos porcentajes fijos. Este enfoque es útil cuando la magnitud o el tamaño de una variable de predicción es significativo al evaluar la precisión de un pronóstico. El MAPE indica qué tanta desviación existe en la predicción en comparación con el valor real (Kamaliah et al., 2017, p. 3).

El error porcentual medio absoluto (MAPE) es una medida relativa que emplea valores absolutos para evitar que los errores positivos y negativos se compensen entre sí. Además, al utilizar errores relativos, permite comparar la precisión de distintos métodos de pronóstico en series de tiempo, independientemente de la escala de los datos (Oracle, s.f.).

Donde:

$$M = \frac{1}{n} \sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right|$$

M = Error de porcentaje medio absoluto (MAPE= *Mean Absolute Percentage Error*)

A_t = Resultado actual de la variable pronosticada

F_t = Pronóstico de la variable en análisis

Ejemplo:

Tabla A1

Ejemplificación de aplicación de la determinación del MAPE

N	Year	Actual	Forecast	Abs diff	Porcentual
1	2016	49,458.00	44,000.00	0.1104	11.0356%
2	2016	39,905.00	46,689.00	0.1700	17.0004%
3	2016	41,088.00	50,127.00	0.2200	21.9991%
4	2016	49,708.00	52,000.00	0.0461	4.6109%
5	2016	40,103.00	48,124.00	0.2000	20.0010%
6	2016	37,886.00	44,000.00	0.1614	16.1379%

Average 15.13%

Nota. Adaptado de Kamaliah, K., Siregar, R. R. S., & Husein, A. M. (2017)

Anexo 2

Matrices inversas

Para poder construir la “X” cantidad de ecuaciones con “m”, variables se utiliza las matrices inversas para construir las ecuaciones a resolver.

Los pasos para construir las ecuaciones con “m” variables son los siguientes:

1. Identificar las variables a crear en la matriz central expresadas como sumatorias
2. Crear la matriz central
3. Multiplicar las variables de las filas con las variables de las columnas para llenar la matriz central
4. Crear la matriz de las variables Y (a la derecha de la matriz central)
5. Multiplicar la variable “y”, con las variables de las columnas
6. Colocar las variables de los intersección (a la izquierda de la matriz derecha)
7. Igualar la columna de la matriz “Y” con la multiplicación de los intersección con la matriz central

Se presenta un ejemplo para construir un modelo con 4 variables. Para eso es necesario construir la ecuación principal de la siguiente forma:

$$Y = a + b_1X_1 + b_2X_2 + b_3X_3$$

Educación i

Donde a, b₁, b₂, y b₃ son los interceptos de las variables; Las variables son X₁, X₂ y X₃.

1. Creación de la matriz central

$$\begin{bmatrix} n & \sum X_1 & \sum X_2 & \sum X_3 \\ \sum X_1 & & & \\ \sum X_2 & & & \\ \sum X_3 & & & \end{bmatrix}$$

2. Multiplicación de las variables de las filas con las variables de las columnas

$$\begin{bmatrix} n & \sum X_1 & \sum X_2 & \sum X_3 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 & \sum X_1 X_3 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 & \sum X_2 X_3 \\ \sum X_3 & \sum X_1 X_3 & \sum X_2 X_3 & \sum X_3^2 \end{bmatrix} \begin{bmatrix} \sum Y \\ \sum X_1 Y \\ \sum X_2 Y \\ \sum X_3 Y \end{bmatrix}$$

3. Creación de la matriz de las variables Y

$$\begin{bmatrix} n & \sum X_1 & \sum X_2 & \sum X_3 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 & \sum X_1 X_3 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 & \sum X_2 X_3 \\ \sum X_3 & \sum X_1 X_3 & \sum X_2 X_3 & \sum X_3^2 \end{bmatrix}$$

4. Multiplicación de la variable y con las variables de las columnas

$$\begin{bmatrix} n & \sum X_1 & \sum X_2 & \sum X_3 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 & \sum X_1 X_3 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 & \sum X_2 X_3 \\ \sum X_3 & \sum X_1 X_3 & \sum X_2 X_3 & \sum X_3^2 \end{bmatrix} \begin{bmatrix} \sum Y \\ \sum X_1 Y \\ \sum X_2 Y \\ \sum X_3 Y \end{bmatrix}$$

5. Adición de las variables de los intersección

$$\begin{bmatrix} a \\ b_1 \\ b_2 \\ b_3 \end{bmatrix} \begin{bmatrix} n & \sum X_1 & \sum X_2 & \sum X_3 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 & \sum X_1 X_3 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 & \sum X_2 X_3 \\ \sum X_3 & \sum X_1 X_3 & \sum X_2 X_3 & \sum X_3^2 \end{bmatrix} \begin{bmatrix} \sum Y \\ \sum X_1 Y \\ \sum X_2 Y \\ \sum X_3 Y \end{bmatrix}$$

6. Igualación de las columna de la matriz “Y” con la multiplicación de los intersección con la matriz central

$$\sum Y = na + b_1 \sum X_1 + b_2 \sum X_2 + b_3 \sum X_3$$

Educación ii

$$\sum YX_1 = a \sum X_1 + b_1 \sum X_1^2 + b_2 \sum X_1 X_2 + b_3 \sum X_1 X_3$$

Educación iii

$$\sum YX_2 = a \sum X_2 + b_1 \sum X_1 X_2 + b_2 \sum X_2^2 + b_3 \sum X_2 X_3$$

Educación iv

$$\sum YX_3 = a \sum X_3 + b_1 \sum X_1 X_3 + b_2 \sum X_2 X_3 + b_3 \sum X_3^2$$

Educación v



ISBN: 978-99983-65-74-2

