



**Un modelo de planeación y proyección financiera como herramienta de apoyo en la toma de
decisiones estratégicas en una empresa comercializadora colombiana**

Por

Luis Eduardo Santa Gómez

Tesis presentada como requisito parcial para obtener el título de
magíster en Administración Financiera

Asesores

Ph. D. Paula María Almonacid Hurtado y Ph. D.

Julián Alberto Pareja Vasseur

UNIVERSIDAD EAFIT

Medellín, agosto, 2022

© 2022 por Luis Eduardo Santa Gómez

Todos los derechos reservados

Dedicatoria

Dedico este trabajo con profundo agradecimiento a mis padres Elías y Flor, que con callos en sus manos me otorgaron la educación (mi mejor regalo). Gracias a mi padre por inculcarme el trabajo duro y a mi madre por enseñarme que nunca se da un paso al costado. Espero que este logro los enorgullezca de la misma forma en que siento orgullo y gratitud por los padres que Dios me regaló.

Agradecimientos

A Dios por la vida y por permitirme hacer lo que me apasiona.

A mis asesores Paula y Julián por su apoyo; sin ellos este trabajo no hubiese sido posible.

A la líder del proceso de planeación financiera de XYZ S. A. Yessica Santis por su apoyo y su comprensión en la realización de este trabajo.

A la familia Moreno Gómez por brindarme una segunda familia y por abrirme las puertas de su hogar. A Sara y a Óscar mi inmensa gratitud por sus consejos y por regalarme dos sobrinos que nunca imaginé tener.

A la familia Moreno Tirado por su amistad, por su apoyo y por creer en mis capacidades. A Diego Moreno en especial por siempre hablarme de forma certera y directa, características de un verdadero amigo.

A mis tías Lisiria y Rocío. Su apoyo siempre estuvo en los momentos oportunos.

“Enthusiasm is common. Endurance is rare” (Angela Duckworth)

Resumen

El presente trabajo surgió por la necesidad de contar con un modelo financiero en la empresa XYZ S. A. que soporte la toma de decisiones estratégicas por parte de la gerencia general y sirva como herramienta de corto plazo para el control financiero. Su elaboración se dividió en dos fases; la primera, conocida como planeación financiera de corto plazo, se elaboró con un horizonte temporal de un año y su objetivo principal es permitir el ejercicio del control financiero; en cuanto a la segunda fase, conocida como planeación financiera de largo plazo, buscó, mediante la utilización de herramientas propias de la ciencia de datos, disminuir la incertidumbre mediante proyecciones con base estadística sólida. Por último, se acudió a las finanzas corporativas y a la analítica para consolidar un modelo de planeación y de proyección financiera que permita el ejercicio del control financiero y la toma de decisiones estratégicas.

Palabras clave: planeación financiera, inteligencia de negocios, valoración de empresas, analítica, generación de valor.

Abstract

The present work arose from the need to have a financial model in the company XYZ S. A. that supports strategic decision-making by the general management and serves as a short-term tool for financial control. Its elaboration was divided into two phases; the first known as short-term financial planning was developed with a time horizon of one year and its main objective is to allow the exercise of financial control, meanwhile, the second phase known as long-term financial planning sought through the use of tools of data science reduce uncertainty through projections

with a solid statistical basis. Finally, through the use of corporate finance and analytics, a financial planning and projection model was consolidated that allows the exercise of financial control and strategic decision-making.

Key words: *financial planning, business intelligence, business valuation, analytics, value generation.*

Tabla de contenido

Capítulo 1: introducción.....	1
1.1. Un breve contexto sobre XYZ S. A.	4
Capítulo 2: marco teórico.....	5
2.1. Analítica y decisiones gerenciales	5
2.2. Estrategia	5
2.3. Inteligencia de negocios	5
2.4. Planeación financiera	6
2.4.1. Planeación financiera de corto plazo: presupuesto empresarial	7
2.4.2. Planeación financiera de largo plazo: plan financiero.....	7
2.5. Analítica de datos	7
2.6. Análisis predictivo	8
2.6.1. Modelos supervisados	8
2.6.1.1. Regresión lineal múltiple	8
2.6.1.2. Bosque aleatorio.....	9
2.6.2. Aprendizaje profundo.....	10
2.6.2.1. Redes neuronales	10
2.6.3. Modelos VAR (autorregresivo vectorial).....	12
2.6.4. Series de tiempo	12
2.6.4.1. Modelos ARIMA.....	13
2.6.4.2. Pronóstico autorregresivo recursivo	13
2.6.4.3. Pronóstico autorregresivo recursivo con variable exógena	13
2.6.4.4. Pronóstico autorregresivo recursivo con predictores personalizados	13
2.6.4.5. Pronóstico multietápico directo.....	13
2.7. Análisis de la literatura y trabajos similares	14
Capítulo 3: metodología.....	18
3.1. Datos utilizados	18
3.2. Esquemas de investigación adoptados	18
3.3. Técnicas matemáticas, estadísticas y econométricas empleadas	20
Capítulo 4: resultados.....	21
4.1. Planeación financiera de corto plazo	21

4.1.1.	Presupuesto de ventas.....	21
4.1.2.	Presupuesto de costos.....	21
4.1.3.	Presupuesto de gastos operacionales.....	21
4.1.3.1.	Gastos directos.....	22
4.1.3.2.	Gastos asignados.....	22
4.1.3.3.	Gastos de nómina.....	22
4.1.4.	Gastos financieros.....	22
4.1.5.	Otros gastos no operacionales.....	23
4.1.6.	Diferencia en cambio.....	23
4.1.7.	Capital de trabajo.....	26
4.1.8.	Capex.....	26
4.2.	Construcción del modelo de corto plazo.....	27
4.3.	Planeación financiera de largo plazo.....	28
4.3.1.	Proyección de ingresos.....	29
4.3.1.1.	Regresión lineal simple.....	29
4.3.1.2.	Bosque aleatorio.....	31
4.3.1.3.	Redes neuronales.....	34
4.3.1.4.	Modelos de series de tiempo (ARIMA).....	35
4.3.1.5.	Pronóstico autorregresivo recursivo.....	42
4.3.1.6.	Pronóstico autorregresivo recursivo con variable exógena.....	46
4.3.1.7.	Pronóstico autorregresivo recursivo con predictores personalizados.....	49
4.3.1.8.	Pronóstico multietápico.....	52
4.3.1.9.	Otros modelos sin buenos resultados en cuanto a predicción (modelos VAR).....	54
4.3.2.	Proyección de costos.....	56
4.3.3.	Proyecciones de gastos operacionales.....	57
4.3.4.	Gastos financieros.....	57
4.3.5.	Otros gastos no operacionales.....	57
4.3.6.	Capital de trabajo.....	58
4.3.7.	Capex.....	58
4.4.	Construcción del modelo de largo plazo.....	58
4.5.	Resultados de la valoración.....	58
4.5.1.	Construcción de los flujos de caja.....	58
4.5.2.	Construcción de las tasas de descuento.....	60

4.5.3.	Valor terminal.....	61
4.5.4.	FCC descontado con el K_u	62
4.5.5.	FCL descontado con el WACC.....	63
4.5.6.	FCL descontado con el WACC ajustado.....	63
4.5.7.	FCA descontado con el K_e	64
4.5.8.	Valor presente ajustado (APV).....	64
Capítulo 5: conclusiones y recomendaciones.....		65

Capítulo 1: introducción

El presente trabajo tuvo como objetivo la creación de un modelo de planeación y de proyección financiera para la empresa XYZ S. A. S. con el que se buscó obtener las proyecciones de corto y de largo plazo que le permitan a la gerencia general tomar decisiones basadas en información oportuna y de calidad. El modelo consta de dos fases: la primera es la planeación financiera de corto plazo, que se materializa en el presupuesto empresarial y que se caracteriza por ser operativo y por su enfoque de control y que contiene la evidencia más clara del efecto de decisiones ya tomadas. La segunda se conoce como planeación financiera de largo plazo y se materializa en el plan financiero, que tiene como principal característica ser estratégico y orientador, pues, como lo manifestaron Gutiérrez Carmona y Gutiérrez González (2018, p. 19), “es una guía para que con la información con que se cuenta hoy se tomen decisiones para enfrentar el futuro”.

La incertidumbre derivada de la volatilidad geopolítica, social y económica que afronta el mundo dificulta el proceso de toma de decisiones y por ello se necesita la creación de modelos que integren diversas áreas del conocimiento, como la analítica y las finanzas, con el fin de crear organizaciones inteligentes que basen sus esquemas de toma de decisiones en información obtenida de acuerdo con bases científicas que garanticen la rigurosidad del método aplicado. La información empleada en el proceso de toma de decisiones empresariales se convierte en conocimiento que se utiliza en los diferentes niveles decisorios y que se transforma en aprendizaje como inteligencia organizacional.

A pesar de que el proceso de toma de decisiones es una actividad que afecta los diferentes procesos de la organización, el presente trabajo se centró en la generación de percepciones desde el punto de vista financiero, para lo que se acudió a las herramientas de proyección empleadas por lo común en la práctica de las finanzas corporativas con el apoyo de la analítica

predictiva. De igual forma, aunque los inductores de valor se encuentran en las decisiones de inversión, financiación y de operación, el foco de la analítica predictiva se centró en los ingresos operacionales y en otras variables externas de interés para la organización que pueden tener cierto poder explicativo, como fue la TRM. Con la utilización de modelos de analítica predictiva, tanto univariados como multivariados, se logró la identificación de tendencias, que no solo se incorporaron en los ingresos operacionales, sino en las demás variables que tuvieron impacto en los resultados, como los gastos operaciones, que se proyectaron por medio de tendencia (asociados con una variable externa proyectada) o de estructura (vinculada con las ventas, cuya proyección se hizo con base en modelos analíticos).

El fin último de la toma de decisiones inteligentes por parte de la organización es la generación de valor, por lo que las proyecciones de corto y de largo plazo permitieron, además de alcanzar los objetivos ya planteados, encontrar un valor adecuado para la firma. La valoración se realizó según cinco métodos, que son consistentes entre sí y que se describen de forma más detallada en la metodología.

Como antes se mencionó, el modelo consta de dos fases; la primera es la planeación financiera de corto plazo, que se materializó en el presupuesto empresarial mensual y su horizonte de planeación fue un año; se elaboró en conjunto con cada uno de los procesos de la organización y su nivel de detalle fue elevado dado que su fin corresponde al control financiero, es decir, las ventas las presupuestó de manera directa el gerente de cada una de las unidades de negocio al tener en cuenta su visión actual del mercado. Los gastos operacionales se dividieron en cuatro subgrupos: el primero fueron los asociados con el proceso de nómina, el segundo los que surgieron de los planes de acción de cada uno de los procesos para el horizonte de un año, el tercero los asignados, que corresponden a los que son necesarios para la operación de la organización y entre ellos se incluyeron los arrendamientos y los servicios públicos y, por último, los que se presupuestaron por su estructura, es decir, de acuerdo con su relación

histórica con las ventas. Por su parte, el capital de trabajo se proyectó con base en el presupuesto mensual de ventas, mientras que las deudas financieras se dividieron en la existente (con sus respectivos cronogramas de amortización y pago de intereses) y la nueva (de conformidad con los requerimientos de financiación). Por último, los accionistas y gerencia general habían previsto determinadas inversiones para el primer año que se consideraron como presupuesto de inversión.

La segunda fase es la planeación financiera de largo plazo, que es menos detallada y específica puesto que su enfoque es la identificación de tendencias que puedan tener efectos sobre los resultados de la organización en un horizonte superior a un año. Para la elaboración de esta fase se emplearon modelos univariados como Arima, pronóstico autorregresivo recursivo, pronóstico autorregresivo recursivo con variables exógenas, pronóstico autorregresivo recursivo con predictores personalizados y pronóstico multietápico directo. En el desarrollo del presente trabajo también se emplearon modelos multivariados como la regresión lineal simple y algoritmos de aprendizaje automático como redes neuronales y bosque aleatorio. Como se verá más adelante, varios de estos modelos se descartaron por carecer de precisión en los testeos. Por su parte, los gastos operacionales y no operacionales se proyectaron por medio de su tendencia (tasa de crecimiento real) y de su estructura (relación histórica con la venta) y el capital de trabajo, las deudas y las inversiones se proyectaron de igual forma que en la fase de corto plazo, pero se cambió la periodicidad de mensual a anual.

El trabajo se abordó mediante un enfoque de construcción conjunta, en el que se involucró a los responsables de todos los procesos para la construcción de la fase de corto plazo. La de largo plazo también tuvo un enfoque participativo, pero con la interacción de menos procesos, porque, como antes se indicó, el foco de la analítica financiera como principal herramienta de esta fase fueron los ingresos operacionales y por esta razón solo se interactuó con los procesos comerciales, con el fin de conocer cuáles variables, tanto internas como externas, podrían

llegar a tener un impacto significativo sobre las ventas futuras de las diferentes unidades de negocio. En este sentido, con la identificación de estas variables se buscó el establecimiento de relaciones de causalidad que no tuvieran una explicación netamente estadística, sino que también tuvieran sentido desde el punto de vista de la operación del negocio y del entorno en el que se desenvuelve. El presente trabajo tuvo como fin mostrar el proceso de construcción del modelo, los resultados encontrados y su relación con trabajos similares y, por último, la formulación de recomendaciones para la organización y para futuros investigadores que deseen continuar por esta línea de investigación.

1.1. Un breve contexto sobre XYZ S. A.

XYZ S. A. es una empresa comercializadora ficticia que surgió como mecanismo de protección de los datos de la compañía real sobre la que se realizó el presente trabajo y consta de cinco unidades de negocio que se evidencian en la línea de ingresos del estado de resultados y a las que se les aplicaron los modelos analíticos de proyección.

Como se aprecia en el modelo en la parte de los anexos, su plan de inversiones se concentró en el corto plazo, lo que también requerirá un amplio esfuerzo en términos de financiación.

Capítulo 2: marco teórico

2.1. Analítica y decisiones gerenciales

Los gerentes de los diferentes procesos se ven sometidos de manera permanente a la toma de decisiones; sin embargo, la velocidad de los mercados y los problemas organizacionales para procesar los datos y convertirlos en información obligan a que dichas decisiones se tomen sin estar basada en información oportuna y de calidad, es decir, carentes del concepto de inteligencia, tal como se expuso en Deloitte (2013, p. 2):

Advanced analytics can allow companies to hedge against volatility and to respond faster, and with greater insight, to changes in the marketplace, to such a degree that the predictive power that analytics offers—in pricing, the supply chain, and other areas—can have an increased impact on how business is done

2.2. Estrategia

La planeación estratégica les permite a las organizaciones transitar desde su estado actual hacia uno futuro deseado mediante la selección de un conjunto de estrategias que se materializarán mediante un portafolio de proyectos: “La estrategia competitiva consiste en ser diferente. Significa la selección deliberada de un conjunto de actividades distintas para entregar una mezcla única de valor” (Porter, 2011, p. 6). En este sentido, la planeación financiera cumple un rol primordial en la evaluación del potencial generador de valor de la estrategia con el fin de apoyar a la gerencia en la toma de decisiones que agreguen valor.

2.3. Inteligencia de negocios

Las decisiones se toman en todo momento y en cada nivel organizacional; sin embargo, las dinámicas del entorno y la premura requerida para adoptarlas no siempre permite que se fundamenten en información oportuna y de calidad de modo que se garantice la debida

generación de valor. Al respecto, Gudivada (2017, pp. 47-48) manifestó: “BI is an umbrella term which refers to an assortment of data analysis tasks to help improve business functions and achieve organizational goals. BI’s focus has been on the enterprise and provided support for strategic decision-making”.

2.4. Planeación financiera

Es el conjunto de actividades necesarias para garantizar la supervivencia de la firma y una herramienta clave de la gestión financiera que comprende y otorga control, mejora el proceso de toma de decisiones y permite lograr los objetivos y las metas organizacionales (Gutiérrez Carmona y Gutiérrez González, 2018, p. 11). De esta manera, la planeación financiera y la inteligencia de negocios comparten objetivos afines porque mientras que la primera busca mejorar el proceso de toma de decisiones con el fin de lograr los objetivos organizacionales, la segunda pretende ser un soporte para el mencionado proceso mediante la generación de información proveniente de los diferentes procesos involucrados en dichas decisiones.

La planificación financiera es una herramienta indispensable para garantizar el logro de los objetivos y su importancia radica en que permiten anticiparse y mostrar los problemas que podrían presentarse en el futuro, hacer un balance de dónde se encuentra la compañía y también establecer el curso que debe seguirse. De igual manera, brinda un marco para determinar el impacto financiero y los efectos de las acciones correctivas (Valle Núñez, 2020, p. 6).

La adecuada planificación financiera les ofrece beneficios a las empresas tales como facilitar que los recursos económicos que manejan se evalúen de manera minuciosa y se tomen las decisiones, tanto financieras como de inversión, con base en la rentabilidad y los rendimientos que se espera obtener y proponer alternativas financieras que las soporten en caso de que la situación del mercado resulte adversa (Valle Núñez, 2020, pp. 6-7).

2.4.1. Planeación financiera de corto plazo: presupuesto empresarial

De acuerdo con Gutiérrez Carmona y Gutiérrez González (2028, p. 18), “Mirar el futuro de la empresa un año adelante. Se elabora el presupuesto, y su preocupación principal es verificar que con el desarrollo normal de sus actividades la entidad alcanzará los resultados previstos”. El horizonte de planificación de esta etapa comprende de un año en adelante, se materializa en el presupuesto empresarial con actualizaciones trimestrales (pronósticos permanentes o *rolling forecasts*) y su principal objetivo es el control financiero del cumplimiento de las metas de corto plazo comerciales y de la ejecución de gastos y una adecuada toma de decisiones de inversión y de financiación.

2.4.2. Planeación financiera de largo plazo: plan financiero

La duración del largo plazo no está definida, pues depende de la visión que tengan del negocio sus propietarios y sus directivos. El plan financiero solo se utiliza para vislumbrar tendencias que podría tomar la empresa en el futuro y así decidir sobre las inversiones que deben realizarse en el presente para darle a la compañía el rumbo deseado (Gutiérrez Carmona y Gutiérrez González, 2018, p. 19). Las herramientas utilizadas en el presente trabajo para identificar dichas tendencias del entorno fueron la analítica predictiva y el aprendizaje automático.

2.5. Analítica de datos

Esta herramienta se empleó en la planeación financiera de largo plazo con el fin de identificar relaciones de causalidad entre los ingresos operacionales de las diferentes unidades de negocios y las variables externas al tener en cuenta que la analítica de datos “is the science of integrating heterogeneous data from diverse sources, drawing inferences, and making

predictions to enable innovation, gain competitive business advantage, and help strategic decision-making” (Gudivada, 2017, p. 31).

2.6. Análisis predictivo

El análisis predictivo es un área de la minería de datos que consiste en la extracción de información existente en los datos y su utilización para predecir tendencias y patrones de comportamiento y puede pudiendo aplicarse en cualquier evento desconocido, ya sea en el pasado, el presente o el futuro. El análisis predictivo se fundamenta en la identificación de relaciones entre variables en eventos pasados para luego explotar dichas relaciones y predecir posibles resultados en futuras situaciones. Ahora bien, hay que tener en cuenta que la precisión de los resultados obtenidos depende en alta proporción de cómo se ha realizado el análisis de los datos, así como de la calidad de las suposiciones (Espino Timón, 2017, p. 6). En el análisis predictivo se emplearon modelos supervisados como la regresión lineal múltiple, el bosque aleatorio, los de aprendizaje profundo, las redes neuronales y los de tipo VAR. De igual forma, se emplearon modelos de series de tiempo como Arima y pronósticos autorregresivo recursivo, autorregresivo recursivo con variable exógena, autorregresivo recursivo con predictores personalizados y multietápico directo.

2.6.1. Modelos supervisados

Son los que se basan en algoritmos que aprenden de los datos introducidos por una persona. En el presente trabajo se utilizaron la regresión lineal múltiple y el bosque aleatorio.

2.6.1.1. Regresión lineal múltiple

Los modelos de regresión múltiple son la extensión de los de regresión simple a dos o más variables explicativas (Carrasquilla-Batista *et al.*, 2016, p. 41). La fórmula es la siguiente:

$$Y = B_0 + B_1X_1 + B_2X_2 + \dots + B_kX_k + E$$

Y: variable explicada, dependiente o de respuesta.

X₁, ..., X_k: variables explicativas, regresores o de respuesta.

E: error aleatorio, es decir, el efecto de todas las variables diferentes a X₁, ..., X_k sobre Y.

B₁, ..., B_k: efecto del aumento de una unidad del regresor correspondiente sobre la respuesta, Y, si los restantes regresores permanecen constantes.

2.6.1.2. Bosque aleatorio


El algoritmo denominado bosque aleatorio es una técnica de aprendizaje supervisado que genera múltiples árboles de decisión sobre un conjunto de datos de entrenamiento. Los resultados obtenidos se combinan a fin de obtener un modelo único más robusto en sus resultados en comparación con los de cada árbol por separado. Cada árbol se obtiene mediante un conjunto de dos etapas:

1. Se genera un número considerable de árboles de decisión con el conjunto de datos.
Cada árbol contiene un subconjunto aleatorio de datos m (predictores) de forma que $m < M$, con $M =$ total de predictores.
2. Cada árbol crece hasta su máxima extensión.

Cada árbol generado por el algoritmo bosque aleatorio contiene un grupo de observaciones aleatorias elegidas mediante el muestro de tipo *bootstrap*, que es una técnica estadística para obtener muestras de una población en las que una observación se puede considerar en más de una muestra. Las observaciones no estimadas en los árboles, también conocidas como *out of the bag*, se utilizan para validar el modelo. Las salidas de todos los árboles se combinan en una salida final, \hat{Y} , llamada ensamblado, que se obtiene mediante alguna regla; por lo general es el promedio, cuando las salidas de los árboles del ensamblado son numéricas, y el conteo

de votos, cuando las salidas de los árboles del ensamblado son categóricas (Espinosa Zúñiga, 2020, p. 3).

Figura 1. Bosque aleatorio



Fuente: Espinosa Zúñiga (2020, p. 3)

2.6.2. Aprendizaje profundo

El aprendizaje profundo es un subconjunto del aprendizaje automático, que, a su vez, es parte de la inteligencia artificial, en el que las redes neuronales, que son algoritmos inspirados en cómo funciona el cerebro humano y aprenden de grandes cantidades de datos.

Los algoritmos de aprendizaje profundo realizan una tarea repetitiva que ayuda a mejorar de manera gradual el resultado a través de capas profundas, lo que permite el aprendizaje progresivo. Este proceso forma parte de una familia más amplia de métodos de aprendizaje automático basados en redes neuronales (IBM, s. f.).

2.6.2.1. Redes neuronales


Según IBM (2021), “una red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información: Funciona simulando un número elevado de unidades de procesamiento interconectadas que parecen versiones abstractas de neuronas”

De acuerdo con Rosas Pabón (2019, p. 33),

Elementos básicos de las redes neuronales

- **Entradas:** Provenientes del exterior o de otra neurona, pueden ser binarias o continuas.
- **Regla de propagación:** Permite obtener a partir de las entradas y los pesos, el valor del potencial postsináptico de la neurona. La función más habitual es la lineal que se basa en la suma ponderada de las entradas con los pesos sinápticos, que formalmente se puede interpretar como el producto escalar de los vectores de entradas y pesos.
- **Peso sináptico:** Define la intensidad de la interacción de la neurona presináptica j y las postsináptica i . Si el peso es positivo tenderá a excitar la neurona postsináptica, si el peso es negativo tenderá a inhibirla.
- **Función de activación:** Una función lineal o no lineal que limita la amplitud de la salida de la neurona.
- **Umbral de activación:** Es el valor del potencial que al superarlo activa la neurona.
- **Función de salida:** Esta función proporciona la salida de la neurona, en función de su estado de activación actual. Muy frecuentemente la función de salida es la función identidad, de modo que el estado de activación de la neurona se considera su propia salida.

Figura 2. Red neuronal



Fuente: Martín del Río y Sanz Molina (1997, p. ...)

2.6.3. Modelos VAR (autorregresivo vectorial)

Se utilizan para modelizar series temporales en contextos multivariantes en los que hay dependencias dinámicas entre múltiples series. La dependencia lineal se puede dar con cierta cantidad de rezagos. La fórmula es la siguiente:

$$Y_t = B_0 + B_1 Y_{t-1} + B_2 Y_{t-2} + \dots + B_p Y_{t-p}$$

en la que se puede observar como la variable dependiente se encuentra explicada por múltiples variables con cierta cantidad de rezagos.

2.6.4. Series de tiempo

La expresión serie de tiempo se utiliza para denotar una secuencia de datos empíricos ordenados en función del tiempo, esto es, que puedan graficarse respecto al tiempo. A diferencia de otros datos usados en diversos estudios estadísticos y econométricos, como los de corte transversal, en las series de tiempo el ordenamiento en función del tiempo es determinante y es parte integral de análisis (Montenegro García, 2010).

2.6.4.1. Modelos ARIMA

El modelo ARIMA permite describir un valor como una función lineal de datos anteriores y de errores debidos al azar; además, puede incluir un componente cíclico o estacional, es decir, debe contener todos los elementos necesarios para describir el fenómeno (De la Fuente Fernández, s. f.).

2.6.4.2. Pronóstico autorregresivo recursivo

Consiste en predecir el valor futuro de una serie temporal en función de su comportamiento pasado (autorregresivo) (Amat Rodrigo, 2022).

2.6.4.3. Pronóstico autorregresivo recursivo con variable exógena

Se dispone de otras variables exógenas cuyos valores en el futuro se predicen mediante simulación y pueden servir como predictores adicionales del modelo (Amat Rodrigo, 2022).

2.6.4.4. Pronóstico autorregresivo recursivo con predictores personalizados

En determinados escenarios puede ser interesante incorporar otras características de la serie temporal, además de los rezagos, por ejemplo, la media móvil de los últimos n valores puede servir para capturar la tendencia de la serie (Amat Rodrigo, 2022), que se comporta de forma similar al pronóstico autorregresivo recursivo, pero con la diferencia de que el usuario define la función empleada para crear los predictores.

2.6.4.5. Pronóstico multietápico directo

Para conseguir predicciones en varias etapas en el futuro, los modelos de pronósticos autorregresivo recursivo y autorregresivo recursivo con predictores personalizados siguen una

estrategia de predicción recursiva en la que cada nueva predicción se basa en la anterior. Una alternativa es entrenar un modelo para cada uno de las etapas que se desea predecir. Esta estrategia, que por lo general se conoce como pronóstico multietápico directo, es más costosa, desde el punto de vista computacional, que la recursiva puesto que requiere entrenar varios modelos. Sin embargo, en algunos escenarios se consiguen mejores resultados. Estos modelos se pueden obtener con la clase y pueden incluir también una o múltiples variables exógenas (Amat Rodrigo, 2022).

2.7. Análisis de la literatura y trabajos similares

La actualidad económica y social exige organizaciones que estén preparadas para afrontar los cada vez más frecuentes cambios del entorno en los ámbitos social, económico y político pues, como bien se sabido, vienen acompañados por fluctuaciones de un sinnúmero de variables que afectan el desempeño organizacional. Por esta razón, para XYZ S. A. es una necesidad preponderante establecer un proceso de toma de decisiones inteligente, fundamentada en información oportuna y de calidad, sobre las variables internas y externas que pueden afectar el logro del objetivo básico financiero, definido por García Serna (1991, p. 5) “como el incremento del patrimonio de los accionistas en armonía con los objetivos asociados con clientes, trabajadores y demás grupos de interés que giran alrededor de la empresa”. De esta manera, si se entiende el liderazgo de la gerencia general en la formulación y la ejecución de la estrategia, la planeación financiera se constituye como un aliado esencial para tomar las decisiones que conlleven el logro de los objetivos y el cumplimiento de la estrategia pues, como propusieron Gutiérrez Carmona y Gutiérrez González (2018, p. 11), “la planeación financiera se entiende como las actividades que se deben realizar para asegurar la supervivencia de la empresa y garantizar a los propietarios que sus planes crearán valor en el futuro”.

Por otra parte, es bien sabido que en las finanzas y la estrategia se cuenta con herramientas suficientemente probadas para evaluar las diferentes alternativas de desarrollo de la empresa para, como conclusión, recomendar el curso de acción que debe seguir la firma para alcanzar el estado futuro que proponen los directivos (Gutiérrez Carmona y Gutiérrez González, 2018, p. 11). Sin embargo, es innegable que los dos mencionados campos han evolucionado con el fin de adaptarse a tendencias como la transformación digital, pues, según (Davenport et al., s. f.),

The amount of data available to organizations every day continues to proliferate at a staggering volume. But technologies such as analytics and artificial intelligence (AI) have the potential to help businesses make better use of these massive volumes of data.

Tal como se antes se expresó, la utilización de dichas tecnologías en el presente trabajo permitió establecer las relaciones entre variables y proyectar las que tuvieron mayor incidencia en la variable de salida (VPN) del modelo de valoración.

De igual forma, “la planificación financiera es una herramienta clave de la gestión financiera que comprende y otorga control, mejora el proceso de toma de decisiones, así como el nivel de logro de objetivos y metas organizacionales” (Valle Núñez, 2020, p. 1). En línea con lo anterior, XYZ S. A. busca mayor articulación entre la planeación financiera y la estratégica, con el fin de garantizar que la estrategia definida por la gerencia esté acorde con la realidad financiera de la empresa, de modo que cumpla los objetivos de generación de riqueza de los accionistas. Sin embargo, en los contextos económicos, políticos y sociales de la actualidad es necesario que la compañía pueda responder de forma más rápida y eficiente a las demandas del mercado para que la satisfacción los objetivos propios de la operación pueda redundar en mayor riqueza para los propietarios.

En años anteriores se llevaron a cabo estudios que demostraron la importancia de la planeación financiera en organizaciones de diversos sectores. Se detallan en seguida tres de dichos estudios. En la Clínica Privada Instituto del Corazón de La Rioja, España, Sassola (2017, p. 55) encontró evidencias de los efectos positivos de disminuir el plazo de cobro de las obras sociales, lo que no solo generó más liquidez, sino que también se coordinó de mejor el plazo de pago a proveedores. La utilización de instrumentos financieros disminuyó saldos de efectivo ocioso y mejoró la productividad, siempre y cuando el índice de apalancamiento financiero no fuese muy elevado. Estas oportunidades y amenazas no se habrían detectado sin una adecuada planificación financiera. De igual forma, el modelo de proyecciones financieras elaborado para el sector de la construcción en México en 2021 concluyó que las variaciones en el entorno macroeconómico afectaron al desempeño financiero de las constructoras de forma importante. Por lo tanto, este tipo de negocios es altamente sensible a impactos exógenos y, a su vez, fue posible medir dichos impactos, en lo primordial en las cuentas relacionadas con acreedores bancarios y con los ingresos por construcción (Martínez González *et al.*, 2021, p. 27). Por último, el modelo de evaluación y de proyección financiera para la Junta Administradora del Fondo de Ahorro y Préstamo de la Universidad de Costa Rica en 2015 encontró que los ingresos esperados por concepto de intereses de la cartera de inversiones no guardaron una relación lógica aritmética con los ingresos que razonablemente se podrían recibir, dados el nivel de la cartera de inversiones y las condiciones del mercado (Bustos Vargas, 2015, p. 77).

Los anteriores ejemplos ilustran cómo la planeación financiera basada en proyecciones de calidad se constituye como una herramienta fundamental para ayudar a la gerencia a lograr los objetivos corporativos en la medida en que, como lo expresaron Gutiérrez Carmona y Gutiérrez González (2018, p. 22), “La planeación financiera no se hace para predecir resultados sino para observar tendencias”. De manera similar, los modelos financieros son

válidos para la toma de decisiones financieras siempre y cuando cumplan las condiciones de “pertinencia, coherencia, verosimilitud y transparencia” planteados por Godet (1995, p. 18), lo que es posible con la integración de las finanzas corporativas y la analítica de datos, si se tiene en cuenta que la última “is the science of integrating heterogeneous data from diverse sources, drawing inferences, and making predictions to enable innovation, gain competitive business advantage, and help strategic decision-making” (Gudivada, 2017, p. 31).

Capítulo 3: metodología

3.1. Datos utilizados

Se obtuvieron diversas bases de datos de acuerdo con el modelo empleado; de esta forma, las predicciones basadas en variables exógenas en su mayoría solo tuvieron un datos mensual entre 2017 y 2021 (60 datos) puesto que algunas variables no contaban con más historia; por su parte, en los modelos fundamentados en la historia de las variables para predecir el futuro, como las series de tiempo, se dispuso de observaciones mensuales de ventas por cada sublínea de producto entre 2006 y 2021 (180 datos).

3.2. Esquemas de investigación adoptados

A continuación se presentan los mecanismos empleados para la recolección de la información:

Tabla 1. Esquemas de investigación

Planeación financiera de corto plazo	Planeación financiera de largo plazo
<ul style="list-style-type: none"> • Presupuesto de ventas: se construyó en conjunto con los procesos comerciales de acuerdo con la visión que los gerentes de las unidades negocios tenían acerca del mercado en el horizonte de un año • Presupuesto de costos: se basó en un margen objetivo • Presupuesto de gastos: se elaboró en conjunto con los procesos generadores de gasto de acuerdo con los planes de ejecución de gastos que se tenían en el marco de la 	<ul style="list-style-type: none"> • Proyección de ventas: se basó en modelos de analítica predictiva supervisados, como la regresión lineal múltiple y el algoritmo de bosque aleatorio, en los que se emplearon variables exógenas para predecir el comportamiento futuro de las ventas para cada unidad de negocio; también se utilizaron modelos de aprendizaje profundo, como redes neuronales y series de tiempo

<p>estrategia de la compañía. De igual forma, se tuvieron en cuenta los gastos fijos presupuestados con base en incrementos tarifarios establecidos en los contratos y los gastos variables presupuestados por estructura, es decir, por su relación con las ventas.</p> <ul style="list-style-type: none"> • Gastos financieros: en conjunto con el proceso de tesorería se plasmaron en los estados financieros de corto plazo los cronogramas de amortización y de pago de intereses de las deudas existentes en el final de 2022. El modelo también mostró en varios meses la necesidad de tomar deuda para financiar los déficits generados por el capital de trabajo o por las inversiones en Capex proyectadas para el horizonte de corto plazo • Otros gastos no operacionales: se presupuestaron por su estructura • Capital de trabajo: con base en el comportamiento de los últimos períodos se estableció un capital de trabajo en número de días y se adoptó como política 	<ul style="list-style-type: none"> • Proyección de costos: se fundamentó en un margen objetivo establecido por la gerencia general para los años venideros • Presupuesto de gastos: los fijos se proyectaron por su tendencia y los variables por su estructura • Gastos financieros: de acuerdo con los cronogramas de amortización de las deudas existentes en el período cero del modelo y de las deudas adquiridas a lo largo de los períodos de planificación para financiar déficits en capital de trabajo y Capex • Otros gastos no operacionales: se proyectaron por su estructura • Capital de trabajo: en el largo plazo se continuó con la política en número de días establecida en el período de corto plazo • Capex: en el período de largo plazo no fue tan ambicioso porque se concentró en el corto plazo. Sin embargo, se contemplaron algunas inversiones adicionales y la reposición de algunos
---	---

<ul style="list-style-type: none"> • Capex: En la estrategia de crecimiento de la compañía tiene una alta concentración en el año 2022, que obligaría a la empresa a tomar deuda para su financiación 	activos fijos, que se depreciarán durante los períodos de planificación de corto y de largo plazo, como los equipos de cómputo
---	--

Fuente: elaboración propia

3.3. Técnicas matemáticas, estadísticas y econométricas empleadas

Como antes se mencionó, para elaborar el modelo se adoptaron las técnicas tradicionalmente empleadas por las finanzas corporativas y se complementó con modelos de aprendizaje automático supervisado, como la regresión lineal múltiple y el bosque aleatorio, con los de aprendizaje profundo, como las redes neuronales y las series de tiempo Arima, los pronósticos autorregresivos recursivos con rezagos, con variable exógena y con predictores personalizados y el pronóstico multietápico directo. Por último, se buscó integrar los objetivos de las finanzas corporativas, la estrategia corporativa y la inteligencia de negocios mediante un modelo financiero para garantizar la toma de decisiones inteligentes basadas en información oportuna y de calidad y que aseguren la creación de valor para los accionistas.

Capítulo 4: resultados

4.1. Planeación financiera de corto plazo

4.1.1. Presupuesto de ventas

Como ante se mencionó, el presupuesto de ventas de corto plazo se elaboró en conjunto con los procesos comerciales de acuerdo con la visión que sus gerentes tenían del mercado y se obtuvieron los siguientes resultados (ver hoja con nombre PyG CP 2022 del anexo de Excel con nombre model de planeación financiera XYZ).

Tabla 2. Presupuesto de ventas

Presupuesto 2022 XYZ S.A.S	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre	Total ventas 2022
Linea1	849.806.160	878.271.047	1.075.868.746	934.723.034	901.426.239	973.575.060	1.250.315.089	1.108.947.954	1.160.446.869	1.320.326.568	1.136.389.993	1.244.805.293	12.834.902.051
Linea2	225.638.525	221.295.221	241.083.021	248.773.893	267.495.343	241.627.074	294.758.395	302.159.670	289.920.259	351.481.657	282.150.606	294.501.983	3.260.885.646
Linea3	842.334.045	811.709.276	781.153.549	780.249.596	783.380.579	882.865.001	816.390.486	916.888.807	916.735.294	817.411.997	916.932.293	916.691.726	10.182.742.650
Linea4	238.831.042	243.708.871	264.180.768	258.527.059	270.708.981	253.886.835	238.415.846	267.040.079	275.714.821	235.502.407	240.586.539	246.499.987	3.033.603.236
Linea5	70.675.644	74.024.208	105.150.679	111.881.984	89.027.973	94.849.810	114.485.170	113.521.302	122.618.872	116.954.325	115.338.236	121.844.872	1.250.373.075
Linea2A	2.309.841	2.410.269	2.611.124	2.711.552	2.912.408	2.862.194	2.811.980	2.912.408	2.912.408	3.012.836	3.012.836	3.213.692	33.693.547
Linea1A	20.278.072	25.980.478	25.311.524	20.278.072	20.278.072	25.980.478	37.048.907	20.278.072	25.311.524	25.980.478	32.015.455	25.311.524	304.052.655
Linea1B	83.546.747	44.241.975	85.824.583	87.993.750	165.785.554	93.533.833	73.524.722	86.939.778	78.987.750	61.800.556	69.111.444	58.437.667	989.728.359
Linea1C	-	-	-	12.755.968	43.983.040	42.159.638	96.732.934	118.144.120	292.457.163	263.917.452	483.259.717	228.492.084	1.581.902.116
Linea6	-	-	-	-	-	-	-	-	-	-	-	-	-
Linea7	-	-	-	-	-	-	-	-	-	-	-	-	-
Linea8	-	-	-	-	-	-	-	-	-	-	-	-	-
Devoluciones	-	-	-	-	-	-	-	-	-	-	-	-	-
Ingresos Operacionales Netos	2.333.420.076	2.301.641.344	2.581.183.995	2.457.894.907	2.544.998.188	2.611.339.923	2.924.483.530	2.936.832.189	3.165.104.962	3.196.388.274	3.278.797.120	3.139.798.828	33.471.883.335

Fuente: elaboración propia

4.1.2. Presupuesto de costos

Con base en los cálculos de margen objetivo del proceso de costos se estableció un margen objetivo mensual del 33,2% para todos los meses de la proyección (ver hoja con nombre PyG CP 2022 del anexo de Excel con nombre model de planeación financiera XYZ.)

4.1.3. Presupuesto de gastos operacionales

En el presupuesto mensual de gastos se consideraron tres tipos de gastos:

4.1.3.1. Gastos directos

Son los presupuestados por los procesos estratégicos, misionales y de apoyo con el fin de aportar al cumplimiento de la estrategia de la compañía; entre los más significativos están los de viajes, los diversos y algunos mantenimientos.

4.1.3.2. Gastos asignados

Corresponden a los que son necesarios para el normal funcionamiento de la compañía; entre los más representativos están los arrendamientos y los servicios públicos, entre otros.

4.1.3.3. Gastos de nómina

Son los de nómina, prestaciones sociales, aportes parafiscales y los demás relacionados con el proceso de gestión y desarrollo humano y los presupuestó el área correspondiente.

4.1.4. Gastos financieros

Se tuvieron en cuenta los calendarios de amortización y de pago de intereses de las deudas existentes (ver hoja de deuda actual del anexo modelo de planeación financiera XYZ), de igual forma, dadas las inversiones proyectadas para 2022 (Capex) y el efectivo mínimo planteado por el ciclo operacional, fue necesario en algunos períodos tomar deuda para garantizar que la empresa siempre tuviera el efectivo mínimo; fue de corto o largo plazo dependiendo de si el faltante de liquidez provenía de déficits en capital de trabajo o si, por el contrario, era necesaria para financiar las inversiones presupuestadas, en su orden.

El saldo mínimo de efectivo se planteó de la siguiente forma:

$$\text{Efectivo mínimo} = \frac{\text{costos} + \text{gastos operacionales}}{365} * \text{ciclo operacional en número de días}$$

Con base en la formula y mediante un condicional se determinaron en el corto plazo los períodos en los que: 1. no fue necesario tomar deuda, 2. se requirió deuda de corto plazo porque el déficit de efectivo provenía del capital de trabajo y 3. fue indispensable tomar deuda de largo plazo porque el déficit de efectivo se debió a falta de recursos para financiar las inversiones presupuestada (ver hoja de flujo de caja del anexo model de planeación financiera XYZ).

Dependiendo si se trataba de corto o de largo plazo, se tomaron en cuenta las condiciones planteadas por el banco:

Tabla 3. Condiciones de endeudamiento

Condiciones deuda largo plazo		Condiciones deuda corto plazo	
Periodo (años)	5	Periodo (años)	1
Tasa de interés		Tasa de interés	
Amortizaciones al año	4	Amortizaciones al año	4
Interes EA	5,12%	Interes EA	5,65%
Interes NAMV	5,00%	Interes NAMV	5,51%
Interes Mensual	0,42%	Interes Mensual	0,46%

Fuente: elaboración propia

4.1.5. Otros gastos no operacionales

Como antes se mencionó, los otros gastos no operacionales se presupuestaron por su estructura, es decir, como un porcentaje sobre la venta de acuerdo con los estados financieros históricos desde 2016.

4.1.6. Diferencia en cambio

Entre los otros gastos está la diferencia en cambio, que se presupuestó en dos pasos: en el primero se identificaron en el balance las partidas generadoras de diferencia en cambio, que fueron una deuda con un proveedor internacional y una deuda con un banco extranjero. De acuerdo con la directriz de los accionistas, aún no se conocen las condiciones de pago con el

proveedor internacional y la deuda con el banco extranjero es de tipo *bullet*, es decir, solo paga intereses, y se renovará de forma indefinida cada año. El segundo paso consistió en proyectar la TRM mensual con base en una caminata aleatoria en la que se tuvieron en cuenta las tasas de intervención de la Reserva Federal de Estados Unidos y del Banco de la República y al mismo tiempo se supuso distribución normal de sus rendimientos.

Datos de entrada

Se partió de la TRM de cierre de 2021 como *spot*, después se calculó la desviación estándar mensual con los datos de los últimos diez años, como tasa local se tomó la de intervención del Banco de la República y la tasa foránea fue la de intervención de la Reserva Federal de Estados Unidos. Por último, el dt se calculó de acuerdo con la periodicidad de la TRM por proyectar y en este fue el cociente entre 12 y 365.

Tabla 4. Datos de entrada

2022	
<i>Spot</i>	3.984,77
Desviacion estandar	3,64%
Tasa local (continua)	5,00%
Tasa foránea (continua)	0,25%
dt	0,033

Fuente: elaboración propia

A continuación se presenta un ejemplo de los resultados arrojados por el modelo

Tabla 5. Proyecciones TRM

Mes	Tendencia	Número aleatorio normal	Término aleatorio	Cambio Esperado en Spot (dS)	Spot Esperado	Drift
0					3.984,77	3.984,77
1	6,22	0,07	1,76	7,99	3992,76	3990,99
2	6,24	-0,57	-15,01	-8,78	3983,98	3997,23
3	6,22	-2,06	-54,22	-48,00	3935,98	4003,45
4	6,15	1,64	42,50	48,64	3984,62	4009,60
5	6,22	0,52	13,75	19,97	4004,60	4015,82
6	6,25	-0,42	-10,96	-4,71	3999,89	4022,07
7	6,25	-0,28	-7,42	-1,18	3998,71	4028,32
8	6,24	0,39	10,25	16,49	4015,21	4034,56
9	6,27	0,29	7,69	13,96	4029,17	4040,83
10	6,29	1,24	32,81	39,10	4068,27	4047,13
11	6,35	-0,44	-11,72	-5,36	4062,91	4053,48
12	6,34	-0,87	-23,23	-16,89	4046,02	4059,82

Fuente: elaboración propia

El componente de tendencia captura la tendencia al alza o a la baja de la TRM según las tasas de intervención, que son un reflejo implícito de la inflación del país correspondiente (mayores devaluaciones por lo general representan mayores inflaciones) y se calcula de la siguiente forma:

$$\text{Tendencia} = (\text{tasa local} - \text{tasa foránea}) * \text{spot} * dt$$

La TRM no solo se mueve de acuerdo con su tendencia, sino que tiene cierta aleatoriedad en su comportamiento; por esta razón, el término aleatorio busca explicar, en conjunto con la tendencia, el comportamiento futuro de la TRM y se calcula con la siguiente fórmula:

$$\text{Término aleatorio} = \text{desvest} * \text{spot} * Z * \sqrt{dt}$$

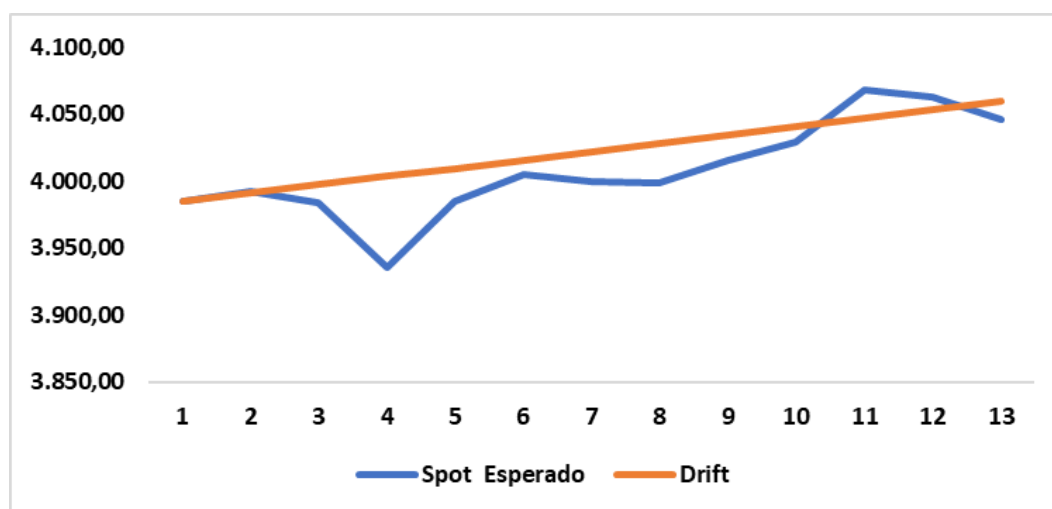
en la que Z es el número aleatorio normal.

$$\text{Cambio esperado en el spot}(ds) = \text{tendencia} + \text{término aleatorio}$$

$$\text{Spot esperado en } (n = 1) = \text{spot}(n = 0) + \text{cambio esperado en el spot}(ds)$$

$$\text{Drift} = \text{spot}(n = 0) + \text{tendencia}(n = 1)$$

Figura 3. Caminata Aleatoria TRM



Fuente: elaboración propia

Ver hoja de la caminata aleatoria de la TRM del anexo model de planeación financiera XYZ, en la que se muestra la proyección, y la hoja de diferencia en cambio del mismo anexo en la que se presenta la proyección de dicha variable generada por las cuentas de balance al tener en cuenta una de las múltiples proyecciones arrojadas por la caminata aleatoria.

4.1.7. Capital de trabajo

En el cálculo del capital de trabajo se consideraron todos los saldos mensuales durante 2021 de las cuentas por cobrar, el inventario y las cuentas por pagar y con base en los ingresos y los costos anualizados se obtuvo el número de días de rotación para cada una de las cuentas en dicho año. Con el número de días de cartera, el de inventarios y el de cuentas por pagar para cada uno de los meses de 2021 se calcularon los saldos para cada uno de los meses de 2022 (ver hoja de KTNO del anexo model de planeación financiera XYZ).

4.1.8. Capex

El presupuesto de inversiones se desprendió de la estrategia de crecimiento de la compañía y se dividió en los seis proyectos siguientes: Cartagena, Barranquilla, Producción, Abastecimiento, Talleres y Modernización de Maquinaria. El detalle de las inversiones y el de

las depreciaciones se observa en la hoja Capex y depreciación del anexo model de planeación financiera XYZ.

4.2. Construcción del modelo de corto plazo

El estado de resultados de corto plazo se elaboró por cuenta contable puesto que su objetivo es garantizar un adecuado control financiero que solo es posible si se mantiene un nivel de detalle pertinente (ver hoja PyG CP 2022 del anexo model de planeación financiera XYZ).

El balance general de corto plazo y el estado de resultados se construyeron mes a mes y el último se relacionó con el primero mediante la utilidad neta acumulada y las depreciaciones porque afectan el valor del activo fijo (ver hoja de balance general del anexo model de planeación financiera XYZ).

El flujo de caja se obtuvo con base en la utilidad operacional, la UODI (utilidad operativa después de impuestos), el FCB (flujo de caja bruto), el FCL (flujo de caja libre), el flujo de caja de la financiación, el flujo de caja del accionista y el flujo de caja del período anterior, para llegar al saldo final de caja.

Tabla 6. Estructura del flujo de caja

Flujo de caja mensual

(=) Utilidad Operacional

(-) Impuesto Operativo

(=) UODI

(+) Ingresos No Operacionales

(-) Gastos No Operacionales

(=) Utilidad No Operacional

(-) Impuesto No Operativo

(=) UNODI

(+) Dep, Amort y Prov

(=) FCB

(+/-) Var. Cartera

(+/-) Var. Inventario

(+/-) Var. Proveedores

(+/-) Inversión KTNO

(=) EGO

(+/-) Proveedor No Operativo

(+/-) Inversiones

(=) FCL

(-) Amortización

(-) Intereses

(-) Otros Gastos Financieros

(+) Beneficio Tx

(+) Préstamos Nuevos

(-) Amortización Deuda Nueva

(-) Intereses Deuda Nueva

(+) Beneficio Tx Deuda Nueva

(+/-) FC de Financiación

(=) FC del Accionista

(+) FC Priodo Anterior

(+) Saldo final

Fuente: elaboración propia

Este esquema del flujo de caja es útil para el ejercicio del control financiero y facilita la valoración mediante diversos métodos, como se verá más adelante (ver hoja de flujo de caja del anexo model de planeación financiera XYZ).

4.3. Planeación financiera de largo plazo

Se asignaron nombres abreviados a las variables, que no se explicaron con el fin de proteger la identidad de la compañía original.

4.3.1. Proyección de ingresos

Como antes se mencionó, se emplearon modelos de analítica predictiva. Dado que la compañía tiene un total de cinco líneas de negocio, a continuación se muestran los resultados de la más significativa, que fue la variable MFB, y los de las demás se presentaron en los anexos del presente trabajo.

4.3.1.1. Regresión lineal simple

En el modelo de regresión las variables Q_MFB, Q_Motos y TRM fueron estadísticamente significativas puesto que su valor de P fue inferior a 0.05; fuera de ello, tuvieron una capacidad explicativa sobre la variable dependiente MFB de 0.898, como lo mostraron los resultados de la regresión.

Tabla 7. Resultados modelo de regresión lineal múltiple

OLS Regression Results						
=====						
Dep. Variable:	MFB	R-squared:	0.898			
Model:	OLS	Adj. R-squared:	0.891			
Method:	Least Squares	F-statistic:	129.2			
Date:	Mon, 16 May 2022	Prob (F-statistic):	7.79e-22			
Time:	00:00:36	Log-Likelihood:	-1033.8			
No. Observations:	48	AIC:	2076.			
Df Residuals:	44	BIC:	2083.			
Df Model:	3					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]

Intercept	-7.339e+09	8.97e+08	-8.182	0.000	-9.15e+09	-5.53e+09
Q_MFB	8.524e+06	7.72e+05	11.041	0.000	6.97e+06	1.01e+07
Q_Motos	4.227e+04	9991.542	4.231	0.000	2.21e+04	6.24e+04
TRM	2.298e+06	2.46e+05	9.334	0.000	1.8e+06	2.79e+06
=====						
Omnibus:	0.563	Durbin-Watson:	1.809			
Prob(Omnibus):	0.755	Jarque-Bera (JB):	0.518			
Skew:	-0.237	Prob(JB):	0.772			
Kurtosis:	2.815	Cond. No.	5.10e+05			

Fuente: elaboración propia

De igual forma, con el test de Breush y Pagan se comprobó la inexistencia de heteroscedasticidad en los errores.


Tabla 8. Test de Breusch - Pagan

```
# breusch-pagan heteroskedasticity test
name = ['Lagrange multiplier statistic', 'p-value',
        'f-value', 'f p-value']
test = sms.het_breuschpagan(results.resid, results.model.exog)
lzip(name, test)

[('Lagrange multiplier statistic', 6.630425852508539),
 ('p-value', 0.156755775110342),
 ('f-value', 1.7229347747295778),
 ('f p-value', 0.16245503140581588)]
```

Fuente: elaboración propia

Figura 4. Errores



Fuente: elaboración propia

Por su parte, con el test de Durbin y Watson no encontró la existencia de autocorrelación en los residuos.

Tabla 9. Resultado test de Durbin Watson


```
sms.durbin_watson(residuals)

1.8204399804619504
```

Fuente: elaboración propia

En el anexo denominado predicciones se presentaron los resultados para la variable MFB por medio de la utilización de los parámetros de la regresión encontrados con los datos de entrenamiento y que tuvieron un ajuste del 0.898. Las proyecciones entre 2022 y 2031 se comportaron como se muestra en la siguiente figura:

Figura 5. Resultados proyección regresión lineal múltiple variable MFB



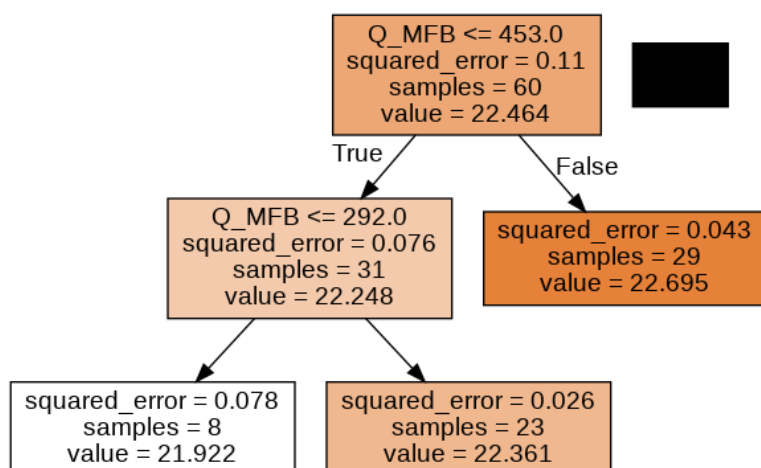
Fuente: elaboración propia

Como se puede observar, las ventas de MFB continuarán teniendo un comportamiento lineal y creciente de acuerdo con las predicciones efectuadas con los parámetros encontrados en el modelo de regresión lineal múltiple.

4.3.1.2. Bosque aleatorio

Con base en el modelo de regresión múltiple se planteó un árbol de tres nodos obteniendo los siguientes resultados.

Figura 6. Bosque aleatorio de tres nodos




Fuente: elaboración propia

Al igual que en el modelo de regresión lineal múltiple, Q_MFB fue la variable más representativa y con mayor capacidad explicativa. A continuación se presenta el error cuadrático medio para los datos de entrenamiento.

Figura 7. Test bosque aleatorio de tres nodos

`Text(0, 0.5, 'y_test')`



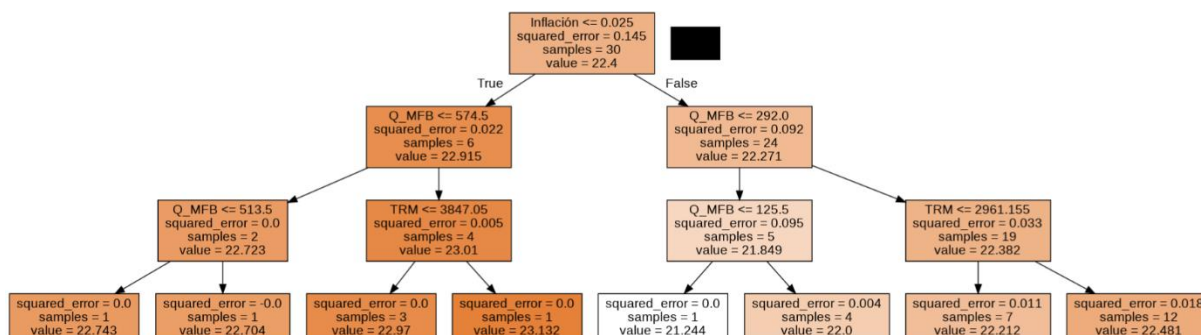
```
mean_squared_error(y_test, pred)
```

```
0.052465022407861085
```

Fuente: elaboración propia

Al ampliar los nodos del modelo se obtuvieron los siguientes resultados:

Figura 8. Bosque aleatorio de cuatro nodos




Fuente: elaboración propia

Además, el error cuadrático medio fue mejor porque el modelo se complejizó y con ello se mejoró el ajuste.

Figura 9. Test bosque aleatorio de cuatro nodos

`Text(0, 0.5, 'y_test')`




```
mean_squared_error(y_test, pred)
```

0.029167200538557682

Fuente: elaboración propia

De igual forma, en el modelo es importante observar la importancia de todas las variables planteadas en el momento de explicar los ingresos (variable MFB):

Figura 10. Importancia de las variables




Fuente: elaboración propia

4.3.1.3. Redes neuronales

El modelo de redes neuronales fue el peor en términos de capacidad explicativa sobre los ingresos (MFB), como se aprecia en la siguiente gráfica. En los anexos del presente trabajo se muestran de forma más detallada los esfuerzos computacionales y estadísticos que se hicieron para predecir los ingresos de cada una de las unidades de negocio mediante este modelo.

Figura 11. Resultados redes neuronales




Fuente: elaboración propia

4.3.1.4. Modelos de series de tiempo (ARIMA)

Estos modelos deben cumplir dos supuestos básicos: el de estacionariedad, que implica que los estadísticos media y varianza de la serie no variaron en función del tiempo y el de no autocorrelación, que significa que los elementos cercanos en el tiempo no guardaron amplia similitud entre sí.


Figura 12. Resultados modelo ARIMA



Fuente: elaboración propia

La gráfica muestra que la media y la varianza sufrieron variaciones con el tiempo, es decir, que la serie no es estacionaria. De igual forma, las gráficas de autocorrelación y de autocorrelación parcial mostraron que la serie también tiene problemas de autocorrelación.


Figura 13. Función de autocorrelación y autocorrelación parcial



Fuente: elaboración propia

Para corregir la autocorrelación y la no estacionariedad se procedió a diferenciar la serie y se llegó a los siguientes resultados:


Figura 14. Función de autocorrelación y autocorrelación parcial sobre la serie diferenciada



Fuente: elaboración propia

Además, si se tiene en cuenta que se está trabajando con ingresos, lo más recomendable es emplear la transformación logarítmica en la serie diferenciada; los resultados se presentan en las siguientes figuras: resultados.


Figura 15. Función de autocorrelación y autocorrelación parcial sobre la serie con transformación logarítmica



Fuente: elaboración propia

Por lo anterior, del modelo se desprendieron tres series: la original, la original diferenciada y la logarítmica diferenciada. A continuación se presentan los resultados obtenidos en cada una:

Figura 16. Resultados entrenamiento y testeo serie original



Fuente: elaboración propia

En la serie original se planteó en los datos de testeo la media como medida de proyección, representada por la línea roja. Sin embargo, los resultados en términos de error cuadrático medio no fueron tan buenos, como se aprecia en la siguiente imagen:

Figura 17. Error cuadrático medio serie original

```
[ ] #Error cuadrático medio
    rmse_in = np.sqrt(mean_squared_error(y_true = pred1_df.loc[train_df.index[1]:train_df.index[-1]]["MFB"],
                                         y_pred = pred1_df.loc[train_df.index[1]:train_df.index[-1]]["MFB_preds"]))

    rmse_out = np.sqrt(mean_squared_error(y_true = pred1_df.loc[test_df.index["MFB"]],
                                         y_pred = pred1_df.loc[test_df.index["MFB_preds"]]))

    print(f"RMSE for In Sample Fit - {rmse_in}")
    print(f"RMSE for In Sample Fit - {rmse_out}")

RMSE for In Sample Fit - 891705138.4413698
RMSE for In Sample Fit - 2881837224.8560414
```

Fuente: elaboración propia

Figura 18. Serie diferenciada una vez: Sarima (1,0,1):

```
SARIMAX Results
Dep. Variable:  MFB_log_diff      No. Observations: 156
Model:          SARIMAX(1, 0, 1)  Log Likelihood  2.132
Date:          Thu, 19 May 2022   AIC              1.737
Time:          00:10:19           BIC              10.886
Sample:        02-01-2006         HQIC             5.453
              - 01-01-2019

Covariance Type: opg
      coef  std err      z    P>|z| [0.025 0.975]
ar.L1 -0.1166  0.100   -1.163  0.245 -0.313  0.080
ma.L1 -0.8131  0.067  -12.187  0.000 -0.944 -0.682
sigma2 0.0565  0.007   8.325  0.000  0.043  0.070
Ljung-Box (L1) (Q):  0.03 Jarque-Bera (JB):  0.26
Prob(Q):              0.87 Prob(JB):    0.88
Heteroskedasticity (H): 0.64 Skew:         -0.08
Prob(H) (two-sided):  0.11 Kurtosis:       2.87
```

Fuente: elaboración propia

Figura 19. Resultados entrenamiento y testeo serie original



Fuente: elaboración propia

Figura 20. Error cuadrático medio serie diferenciada

```
#Error cuadrático medio.
rmse_in = np.sqrt(mean_squared_error(y_true = pred2_df.loc[train_df.index[1]:train_df.index[-1]]["MFB"],
                                     y_pred = pred2_df.loc[train_df.index[1]:train_df.index[-1]]["MFB_preds"]))

rmse_out = np.sqrt(mean_squared_error(y_true = pred2_df.loc[test_df.index]["MFB"],
                                     y_pred = pred2_df.loc[test_df.index]["MFB_preds"]))

print(f"RMSE for In Sample Fit - {rmse_in}")
print(f"RMSE for In Sample Fit - {rmse_out}")

RMSE for In Sample Fit - 891705138.4413698
RMSE for In Sample Fit - 3098996057.9101505
```

Fuente: elaboración propia

A diferencia de la serie original, en este caso se incrementó el error cuadrático medio.

Figura 21. Serie con transformación logarítmica diferenciada cuatro veces de acuerdo con los rezagos de la gráfica de autocorrelación parcial (1,0,1) (1,0,1,4):

SARIMAX Results

Dep. Variable: MFB_log_diff No. Observations: 156

Model: SARIMAX(1, 0, 1)x(1, 0, 1, 4) Log Likelihood: 2.150

Date: Thu, 19 May 2022 AIC: 5.700

Time: 00:10:35 BIC: 20.950

Sample: 02-01-2006 HQIC: 11.894

- 01-01-2019

Covariance Type: opg


	coef	std err	z	P> z	[0.025	0.975]
ar.L1	-0.1189	0.102	-1.167	0.243	-0.319	0.081
ma.L1	-0.8099	0.071	-11.458	0.000	-0.948	-0.671
ar.S.L4	0.0529	5.107	0.010	0.992	-9.956	10.062
ma.S.L4	-0.0693	5.109	-0.014	0.989	-10.082	9.943
sigma2	0.0565	0.007	8.293	0.000	0.043	0.070

Ljung-Box (L1) (Q): 0.03 Jarque-Bera (JB): 0.28
 Prob(Q): 0.87 Prob(JB): 0.87

Heteroskedasticity (H): 0.64 Skew: -0.08
 Prob(H) (two-sided): 0.11 Kurtosis: 2.86

Fuente: elaboración propia

Figura 22. Resultados entrenamiento y testeo serie con transformación logarítmica



Fuente: elaboración propia

Figura 23. Error cuadrático medio serie con transformación logarítmica

```
#Error cuadrático medio.
rmse_in = np.sqrt(mean_squared_error(y_true = pred3_df.loc[train_df.index[1]:train_df.index[-1]]["MFB"],
                                     y_pred = pred3_df.loc[train_df.index[1]:train_df.index[-1]]["MFB_preds"]))

rmse_out = np.sqrt(mean_squared_error(y_true = pred3_df.loc[test_df.index]["MFB"],
                                     y_pred = pred3_df.loc[test_df.index]["MFB_preds"]))

print(f"RMSE for In Sample Fit - {rmse_in}")
print(f"RMSE for In Sample Fit - {rmse_out}")

RMSE for In Sample Fit - 891705138.4413698
RMSE for In Sample Fit - 2495708977.1001635
```

Fuente: elaboración propia

Con la transformación logarítmica se obtuvo el mejor resultado en los datos de testeo en términos de error cuadrático medio. Por esta razón se empleó el modelo con logaritmo diferenciado las proyecciones y se llegó a los siguientes resultados de forma resumida. En el anexo denominado series de tiempo se presentan los resultados para cada unidad de negocio. A continuación se ofrece un ejemplo resumido de la proyección mediante el modelo.

Figura 24. Resultados de la proyección empleando el modelo con transformación logarítmica

```
# Crear forecaster
forecaster = ForecasterAutoreg(RandomForestRegressor(random_state=123), lags=10)
forecaster.fit(y=X['MFB'])
forecaster.predict(steps=120)

192    7.008249e+09
193    6.327924e+09
194    6.466383e+09
195    6.614289e+09
196    6.953239e+09
...
307    5.022027e+09
308    5.502499e+09
309    4.881346e+09
310    5.396032e+09
311    4.972974e+09
Name: pred, Length: 120, dtype: float64
```


Fuente: elaboración propia

4.3.1.5. Pronóstico autorregresivo recursivo

Se dividió la serie en dos: la de datos de entrenamiento y la de datos de testeo:

Figura 25. Entrenamiento y testeo modelo autorregresivo recursivo


Fechas train : 2006-01-01 00:00:00 --- 2018-12-01 00:00:00 (n=156)
 Fechas test : 2019-01-01 00:00:00 --- 2021-12-01 00:00:00 (n=36)



Fuente: elaboración propia

Se planteó de forma preliminar un modelo que tuvo en cuenta un solo rezago para la predicción en los datos de testeo y los siguientes fueron los resultados:

Figura 26. Predicción en los datos de testeo modelo autorregresivo recursivo



Error de test (mse): 1.6120795280222163e+19

Fuente: elaboración propia

Optimización de los hiperparámetros

Luego, mediante un código de optimización de hiperparámetros (rezagos) se encontró que la cantidad óptima de rezagos fue diez:

Figura 27. Optimización de los hiperparámetros del modelo autorregresivo recursivo

```

Number of models compared: 12
loop lags_grid: 0% | 0/2 [00:00<?, ?it/s]
loop param_grid: 0% | 0/6 [00:00<?, ?it/s]
loop param_grid: 17% | 1/6 [00:01<00:05, 1.19s/it]
loop param_grid: 33% | 2/6 [00:06<00:15, 3.85s/it]
loop param_grid: 50% | 3/6 [00:08<00:08, 2.67s/it]
loop param_grid: 67% | 4/6 [00:14<00:07, 3.93s/it]
loop param_grid: 83% | 5/6 [00:15<00:02, 2.95s/it]
loop param_grid: 100% | 6/6 [00:21<00:00, 4.17s/it]
loop lags_grid: 50% | 1/2 [00:21<00:21, 21.80s/it]
loop param_grid: 0% | 0/6 [00:00<?, ?it/s]
loop param_grid: 17% | 1/6 [00:01<00:06, 1.31s/it]
loop param_grid: 33% | 2/6 [00:07<00:17, 4.28s/it]
loop param_grid: 50% | 3/6 [00:08<00:08, 2.89s/it]
loop param_grid: 67% | 4/6 [00:15<00:08, 4.44s/it]
loop param_grid: 83% | 5/6 [00:17<00:03, 3.37s/it]
loop param_grid: 100% | 6/6 [00:23<00:00, 4.44s/it]
loop lags_grid: 100% | 2/2 [00:45<00:00, 22.78s/it]
`Forecaster` refitted using the best-found lags and parameters, and the whole data set:
Lags: [ 1 2 3 4 5 6 7 8 9 10]
Parameters: {'max_depth': 10, 'n_estimators': 500}
Backtesting metric: 1.0960032920937316e+18

```

Fuente: elaboración propia

De las alternativas evaluadas, la anterior fue la que tuvo la mejor métrica en las pruebas retrospectivas, como se evidencia a continuación:


Figura 28. Rezagos óptimos

	lags	params	metric	max_depth	n_estimators
5	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 10, 'n_estimators': 500}	1.096003e+18	10	500
4	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 10, 'n_estimators': 100}	1.097699e+18	10	100
3	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 5, 'n_estimators': 500}	1.170617e+18	5	500
2	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 5, 'n_estimators': 100}	1.190295e+18	5	100
10	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 10, 'n_estimators': 100}	1.359095e+18	10	100
11	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 10, 'n_estimators': 500}	1.411928e+18	10	500
8	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 5, 'n_estimators': 100}	1.420665e+18	5	100
0	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 3, 'n_estimators': 100}	1.437056e+18	3	100
1	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	{'max_depth': 3, 'n_estimators': 500}	1.451961e+18	3	500
9	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 5, 'n_estimators': 500}	1.452785e+18	5	500
6	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 3, 'n_estimators': 100}	1.501364e+18	3	100
7	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 3, 'n_estimators': 500}	1.577283e+18	3	500

Fuente: elaboración propia

A pesar de la optimización de los hiperparámetros, no se lograron mejoras en términos de error cuadrático medio.

Figura 29. Predicción en los datos de testeo después de optimizar los hiperparámetros



Fuente: elaboración propia

Figura 30. Error cuadrático medio después de optimizar los hiperparámetros

```
# Error de test
# =====
error_mse = mean_squared_error(
    y_true = datos_test['MFB'],
    y_pred = predicciones
)

print(f"Error de test (mse) {error_mse}")
```

Error de test (mse) 7.151503698966911e+18

Fuente: elaboración propia

Por último, al evaluar la importancia de los predictores se obtuvieron los siguientes resultados, que arrojan al rezago número siete como el más importante en el momento de predecir:

Figura 31. Importancia de los predictores


	feature	importance
0	lag_1	0.108289
1	lag_2	0.084223
2	lag_3	0.061873
3	lag_4	0.149176
4	lag_5	0.128596
5	lag_6	0.084034
6	lag_7	0.175289
7	lag_8	0.064780
8	lag_9	0.085118
9	lag_10	0.058623

Fuente: elaboración propia

4.3.1.6. Pronóstico autorregresivo recursivo con variable exógena

Para el caso de los MFB se empleó como variable más significativa Q_MFB , que en el modelo de regresión lineal múltiple fue la más importante en cuanto a correlación. Al tener en cuenta de forma preliminar un rezago se llegó a los siguientes resultados:

Figura 32. Entrenamiento y testeo modelo autorregresivo recursivo con variable exógena



Error de test (mse): 5.329354900030055e+18

Fuente: elaboración propia

optimización de los hiperparámetros

La optimización arrojó 12 como el número adecuado de rezagos para considerar en el cálculo de las predicciones.

Figura 33. Optimización de los hiperparámetros modelo autorregresivo recursivo con variable exógena

```

Number of models compared: 27
loop lags_grid: 0% | 0/3 [00:00<?, ?it/s]
loop param_grid: 0% | 0/9 [00:00<?, ?it/s]
loop param_grid: 11% | 1/9 [00:00<00:03, 2.37it/s]
loop param_grid: 22% | 2/9 [00:01<00:04, 1.52it/s]
loop param_grid: 33% | 3/9 [00:05<00:12, 2.10s/it]
loop param_grid: 44% | 4/9 [00:05<00:07, 1.43s/it]
loop param_grid: 56% | 5/9 [00:06<00:04, 1.19s/it]
loop param_grid: 67% | 6/9 [00:09<00:06, 2.03s/it]
loop param_grid: 78% | 7/9 [00:10<00:02, 1.50s/it]
loop param_grid: 89% | 8/9 [00:11<00:01, 1.26s/it]
loop param_grid: 100% | 9/9 [00:14<00:00, 2.05s/it]
loop lags_grid: 33% | 1/3 [00:14<00:29, 14.85s/it]
loop param_grid: 0% | 0/9 [00:00<?, ?it/s]
loop param_grid: 11% | 1/9 [00:00<00:03, 2.41it/s]
loop param_grid: 22% | 2/9 [00:01<00:04, 1.60it/s]
loop param_grid: 33% | 3/9 [00:04<00:11, 1.96s/it]
loop param_grid: 44% | 4/9 [00:05<00:06, 1.37s/it]
loop param_grid: 56% | 5/9 [00:05<00:04, 1.15s/it]
loop param_grid: 67% | 6/9 [00:09<00:05, 2.00s/it]
loop param_grid: 78% | 7/9 [00:10<00:02, 1.48s/it]
loop param_grid: 89% | 8/9 [00:10<00:01, 1.27s/it]
loop param_grid: 100% | 9/9 [00:15<00:00, 2.18s/it]
loop lags_grid: 67% | 2/3 [00:29<00:14, 14.99s/it]
loop param_grid: 0% | 0/9 [00:00<?, ?it/s]
loop param_grid: 11% | 1/9 [00:00<00:04, 1.74it/s]
loop param_grid: 22% | 2/9 [00:01<00:04, 1.44it/s]
loop param_grid: 33% | 3/9 [00:04<00:12, 2.04s/it]
loop param_grid: 44% | 4/9 [00:05<00:07, 1.41s/it]
loop param_grid: 56% | 5/9 [00:06<00:04, 1.17s/it]
loop param_grid: 67% | 6/9 [00:10<00:06, 2.07s/it]
loop param_grid: 78% | 7/9 [00:10<00:03, 1.53s/it]
loop param_grid: 89% | 8/9 [00:11<00:01, 1.30s/it]
loop param_grid: 100% | 9/9 [00:14<00:00, 2.03s/it]
loop lags_grid: 100% | 3/3 [00:44<00:00, 14.95s/it]
`Forecaster` refitted using the best-found lags and parameters, and the whole data set:
Lags: [ 1 2 3 4 5 6 7 8 9 10 11 12]
Parameters: {'max_depth': 10, 'n_estimators': 500}
Backtesting metric: 8.524278593119983e+17

```

Fuente: elaboración propia

Como se muestra a continuación, de las alternativas evaluadas la anterior fue la mejor en cuanto a métrica de pruebas retrospectivas:


Figura 34. Rezagos óptimos

	lags	params	metric	max_depth	n_estimators
17	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12]	{'max_depth': 10, 'n_estimators': 500}	8.524279e+17	10	500
19	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 3, 'n_estimators': 100}	8.560953e+17	3	100
14	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12]	{'max_depth': 5, 'n_estimators': 500}	8.595905e+17	5	500
18	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 3, 'n_estimators': 50}	8.623338e+17	3	50
22	[1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14...]	{'max_depth': 5, 'n_estimators': 100}	8.625379e+17	5	100

Fuente: elaboración propia

Con la optimización de los hiperparámetros se logró mejorar el error cuadrático medio, como se muestra a continuación:

Figura 35. Predicción de los datos de testeo después de la optimización de los hiperparámetros



Fuente: elaboración propia

Figura 36. Error cuadrático medio después de la optimización de los hiperparámetros

```
# Error test
# =====
error_mse = mean_squared_error(y_true = datos_test['Ventas'], y_pred = predicciones)
print(f"Error de test (mse) {error_mse}")

Error de test (mse) 4.5265545629710945e+18
```

Fuente: elaboración propia

En seguida se presenta un ejemplo de las predicciones que se lograron con este modelo. En el anexo denominado pronóstico autorregresivo recursivo con variable exógena (MFB) se ofrece la información con mayor detalle.

Figura 37. Proyecciones modelo autorregresivo recursivo con variable exógena

```
# Crear forecaster
forecaster = ForecasterAutoreg(RandomForestRegressor(random_state=123), lags=12)
forecaster.fit(y=datos['Ventas'])
forecaster.predict(steps=120)


2022-01-01    7.468659e+09
2022-02-01    6.050428e+09
2022-03-01    7.411034e+09
2022-04-01    7.713346e+09
2022-05-01    5.793439e+09
...
2031-08-01    8.439586e+09
2031-09-01    8.409141e+09
2031-10-01    8.366097e+09
2031-11-01    8.399312e+09
2031-12-01    8.398196e+09
Freq: MS, Name: pred, Length: 120, dtype: float64
```

Fuente: elaboración propia

4.3.1.7. Pronóstico autorregresivo recursivo con predictores personalizados

Al plantear el modelo con un solo rezago para los datos de entrenamiento y testeo se obtuvieron los siguientes resultados:

Figura 38. Entrenamiento y testeo modelo autorregresivo recursivo con predictores personalizados



Fuente: elaboración propia

Figura 39. Error cuadrático medio modelo autorregresivo recursivo con predictores personalizados

```
# Error test
# =====
error_mse = mean_squared_error(
    y_true = datos_test['MFB'],
    y_pred = predicciones
)

print(f"Error de test (mse): {error_mse}")

Error de test (mse): 8.00081525689157e+18
```

Fuente: elaboración propia

Figura 40. Optimización de los hiperparámetros

```

Number of models compared: 6
loop lags_grid: 0%| | 0/1 [00:00<?, ?it/s]
loop param_grid: 0%| | 0/6 [00:00<?, ?it/s]
loop param_grid: 17%| | 1/6 [00:01<00:05, 1.16s/it]
loop param_grid: 33%| | 2/6 [00:06<00:14, 3.65s/it]
loop param_grid: 50%| | 3/6 [00:07<00:07, 2.53s/it]
loop param_grid: 67%| | 4/6 [00:13<00:07, 3.62s/it]
loop param_grid: 83%| | 5/6 [00:14<00:02, 2.72s/it]
loop param_grid: 100%| | 6/6 [00:19<00:00, 3.55s/it]
loop lags_grid: 100%| | 1/1 [00:19<00:00, 19.34s/it]
`Forecaster` refitted using the best-found lags and parameters, and the whole data set:
Lags: custom predictors
Parameters: {'max_depth': 10, 'n_estimators': 500}
Backtesting metric: 1.391474055089675e+18

```

Fuente: elaboración propia

Para el caso de este modelo, más que tener en cuenta rezagos, se consideró la combinación de bosque aleatorio óptima, que para el caso fue una profundidad de diez nodos y 500 estimadores.

Figura 41. Rezagos óptimos

	lags	params	metric	max_depth	n_estimators
5	custom predictors	{'max_depth': 10, 'n_estimators': 500}	1.391474e+18	10	500
4	custom predictors	{'max_depth': 10, 'n_estimators': 100}	1.393699e+18	10	100
3	custom predictors	{'max_depth': 5, 'n_estimators': 500}	1.418819e+18	5	500
2	custom predictors	{'max_depth': 5, 'n_estimators': 100}	1.448823e+18	5	100
1	custom predictors	{'max_depth': 3, 'n_estimators': 500}	1.525379e+18	3	500
0	custom predictors	{'max_depth': 3, 'n_estimators': 100}	1.627590e+18	3	100

Fuente: elaboración propia

Con la optimización de los hiperparámetros se logró reducir el error cuadrático medio, como se muestra a continuación:

Figura 42. Predicción de los datos de prueba después de la optimización de los hiperparámetros

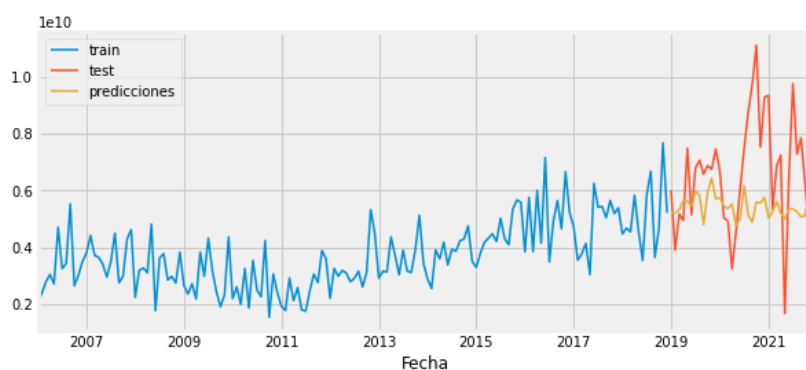

```
# Resultados Grid Search
# -----
resultados_grid.head()
```

	lags	params	metric	lasso_alpha
9	[1, 2, 3, 4, 5]	{'lasso__alpha': 100000.0}	3.038182e+18	100000.000000
8	[1, 2, 3, 4, 5]	{'lasso__alpha': 7742.636826811277}	3.038323e+18	7742.636827
7	[1, 2, 3, 4, 5]	{'lasso__alpha': 599.4842503189421}	3.038334e+18	599.484250
6	[1, 2, 3, 4, 5]	{'lasso__alpha': 46.41588833612782}	3.038335e+18	46.415888
5	[1, 2, 3, 4, 5]	{'lasso__alpha': 3.593813663804626}	3.038335e+18	3.593814

Fuente: elaboración propia

Como se presenta a continuación, en términos de error cuadrático medio los resultados fueron mejores:

Figura 46. Predicción de los datos de testeo después de la optimización de los hiperparámetros



Fuente: elaboración propia

Figura 47. Error cuadrático medio después de la optimización de los hiperparámetros

```
# Error test
# -----
error_mse = mean_squared_error(y_true = datos_test['MFB'], y_pred = predicciones)
print(f"Error de test (mse) {error_mse}")


Error de test (mse) 5.459967255701925e+18
```

Fuente: elaboración propia

4.3.1.8. Pronóstico multietápico

Al emplear el modelo con un solo rezago se obtuvieron los siguientes resultados:


Figura 48. Entrenamiento y testeo modelo multietápico



Fuente: elaboración propia

Figura 49. Optimización de hiperparámetros

Con la optimización de los hiperparámetros se obtuvo un mejor error de testeo.



Fuente: elaboración propia

Un ejemplo de la proyección arrojada por este modelo es la siguiente. En el anexo correspondiente a proyecciones de etapas múltiples para las diferentes unidades de negocio se presenta a información con mayor detalle.

Figura 50. Proyección después de la optimización de los hiperparámetros

```
# Crear forecaster
forecaster = ForecasterAutoreg(RandomForestRegressor(random_state=123), lags=3)
forecaster.fit(y=datos['MFB'])
forecaster.predict(steps=120)

2022-01-01    5.639278e+09
2022-02-01    6.002384e+09
2022-03-01    6.150827e+09
2022-04-01    5.036736e+09
2022-05-01    5.759159e+09
...
2031-08-01    5.227786e+09
2031-09-01    5.044170e+09
2031-10-01    5.082636e+09
2031-11-01    4.884182e+09
2031-12-01    5.077416e+09
Freq: MS, Name: pred, Length: 120, dtype: float64
```

Fuente: elaboración propia

4.3.1.9. Otros modelos sin buenos resultados en cuanto a predicción (modelos VAR)

En el comienzo se planteó un modelo que predijera la venta de MFB por medio de la utilización de todas las variables para más tarde seleccionar las que tuvieran valor de P inferior a 0.05.

Figura 51. Rezagos por variable modelo VAR

Results for equation MFB

	coefficient	std. error	t-stat	prob
const	0.052423	0.047553	1.102	0.270
L1.Brent	0.726205	0.630686	1.151	0.250
L1.TRM	-2.108824	2.260781	-0.933	0.351
L1.Inflación	-1.547793	0.640217	-2.418	0.016
L1.Q_MFB	0.787689	0.387513	2.033	0.042
L1.Q_Vehiculos	0.567629	0.411940	1.378	0.168
L1.Q_Motos	-0.585229	0.272350	-2.149	0.032
L1.Precio_Combustible	0.819529	1.502987	0.545	0.586
L1.Precio_aluminio	-3.921564	1.121654	-3.496	0.000
L1.MFB	-1.906080	0.488937	-3.898	0.000
L1.BOTES	0.118701	0.192952	0.615	0.538
L1.Otros_Nautico	0.070554	0.111505	0.633	0.527
L1.Lubricantes	0.342721	0.343926	0.996	0.319
L1.Agricola_Energia	0.191411	0.273721	0.699	0.484
L1.Ambiental	-0.168713	0.102853	-1.640	0.101
L1.Repuestos	-0.135216	0.290289	-0.466	0.641
L1.Otros_Negocios	0.301972	0.120907	2.498	0.013
L2.Brent	0.430439	0.886552	0.486	0.627
L2.TRM	-2.652330	2.223014	-1.193	0.233
L2.Inflación	1.078437	0.760584	1.418	0.156
L2.Q_MFB	0.831703	0.429362	1.937	0.053
L2.Q_Vehiculos	-0.279430	0.325847	-0.858	0.391
L2.Q_Motos	0.326604	0.288675	1.131	0.258
L2.Precio_Combustible	0.484914	1.561444	0.311	0.756
L2.Precio_aluminio	-3.292381	1.316393	-2.501	0.012
L2.MFB	-1.274928	0.559610	-2.278	0.023
L2.BOTES	0.110576	0.154050	0.718	0.473
L2.Otros_Nautico	0.126635	0.086233	1.469	0.142
L2.Lubricantes	0.051709	0.261225	0.198	0.843
L2.Agricola_Energia	0.009547	0.273564	0.035	0.972
L2.Ambiental	-0.160988	0.090366	-1.782	0.075
L2.Repuestos	0.294626	0.287174	1.026	0.305
L2.Otros_Negocios	-0.150127	0.124773	-1.203	0.229

Fuente: elaboración propia

Con posterioridad, mediante el test de Durbin y Watson se buscó detectar problemas de autocorrelación y se alcanzaron resultados en el rango entre 1.5 y 2.5, que se consideran adecuados en dicho test.

Figura 52. Test de Durbin Watson

```

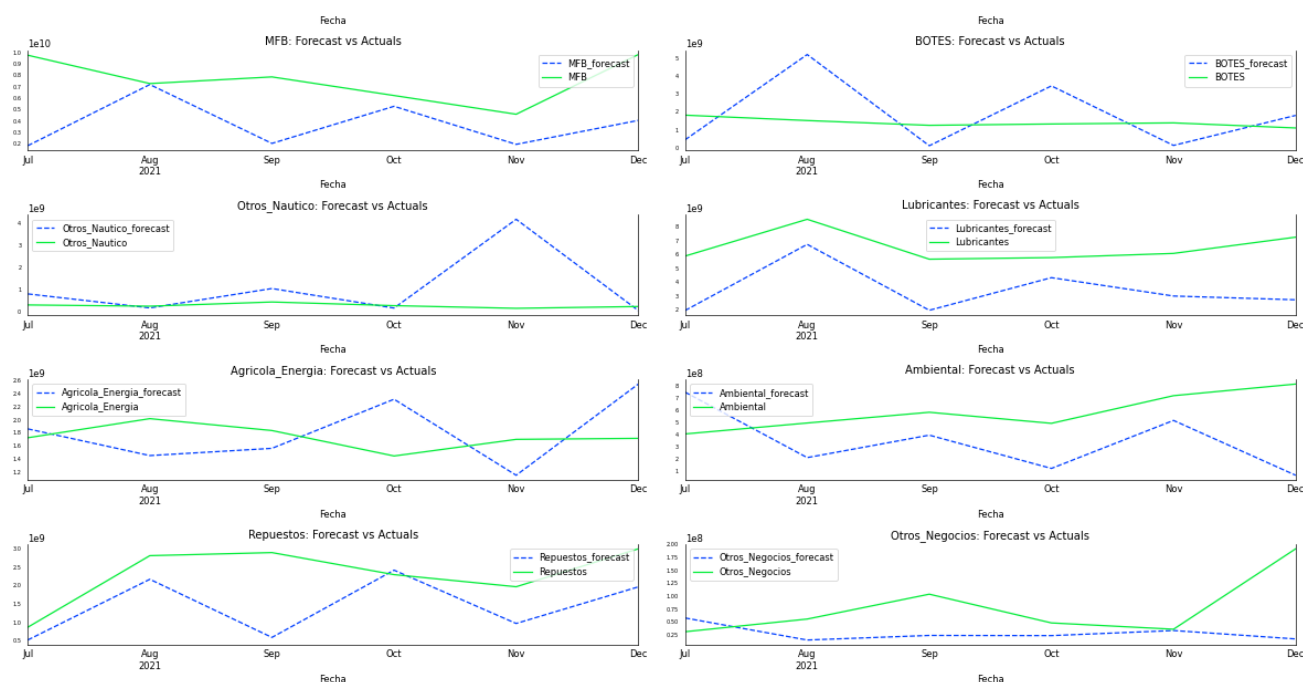
Durbin-Watson statistic for:
Brent --> 1.43
-----
Durbin-Watson statistic for:
TRM --> 1.68
-----
Durbin-Watson statistic for:
Inflación --> 1.73
-----
Durbin-Watson statistic for:
Q_MFB --> 1.79
-----
Durbin-Watson statistic for:
Q_Vehiculos --> 1.68
-----
Durbin-Watson statistic for:
Q_Motos --> 1.67
-----
Durbin-Watson statistic for:
Precio_Combustible --> 1.59
-----
Durbin-Watson statistic for:
Precio_aluminio --> 1.51
-----
Durbin-Watson statistic for:
MFB --> 1.58
-----
Durbin-Watson statistic for:
BOTES --> 1.75
-----
Durbin-Watson statistic for:
Otros_Nautico --> 1.68
-----
Durbin-Watson statistic for:
Lubricantes --> 1.98
-----
Durbin-Watson statistic for:
Agricola_Energia --> 2.15
-----
Durbin-Watson statistic for:
Ambiental --> 1.81
-----
Durbin-Watson statistic for:
Repuestos --> 1.7
-----
Durbin-Watson statistic for:
Otros_Negocios --> 2.11

```

Fuente: elaboración propia

Sin embargo, en el momento de utilizar el modelo para la predicción en los datos de testeo se encontró que el modelo no predijo de forma adecuada las variables objetivo, como se muestra a continuación:

Figura 53. Resultados de testeo modelo VAR



Fuente: elaboración propia

Mediante el criterio del error porcentual absoluto medio o MAPE, forma abreviada proveniente de la expresión en inglés *mean absolute percentage error*, se halló que la eficiencia de las predicciones fue de tan solo el 18.8%.

Figura 54. Asertividad de la predicción

```
var_mape = metrics.mean_absolute_percentage_error(Datos1_test_to_plot, Datos1_var_pred_inv)

var_model_accuracy = 1 - var_mape
print("The accuracy of the VAR out-of-sample prediction is:")
print("-----")
print(round(var_model_accuracy, 3))

The accuracy of the VAR out-of-sample prediction is:
-----
0.188
```

Fuente: elaboración propia

4.3.2. Proyección de costos

Se calcularon los costos para cada año, con un margen objetivo que osciló entre 32.5% y 33.2%, de acuerdo con las expectativas de la gerencia general y de los accionistas, tal como se hizo en el modelo de corto plazo.

4.3.3. Proyecciones de gastos operacionales

Se proyectaron por su tendencia los gastos fijos y por su estructura los variables. En los primeros se tomaron como base las tasas de crecimiento real, como se observa en la hoja de gastos de largo plazo del anexo model de planeación financiera XYZ correspondiente a la valoración, calculadas por medio de la siguiente fórmula:

$$Tasa\ de\ crecimiento\ real = \frac{(1 + \text{tasa de crecimiento nominal})}{(1 + \text{tasa de inflación o de la variación del PIB})} - 1$$

Más tarde la tasa de crecimiento se aplicó al gasto proyectado del período anterior.

4.3.4. Gastos financieros

Al igual que en el modelo de corto plazo, se continuó con las deudas existentes y con sus respectivos cronogramas de amortización y de pago de intereses y se adquirieron nuevas deudas de acuerdo con las necesidades de financiación anuales. En el largo plazo la compañía no necesitaría financiación dado que el grueso de la inversión se hará en el corto plazo (2022), según el plan estratégico, y en adelante se esperó el período de recuperación de la inversión y una financiación adicional para reposición de equipos de cómputo en 2024, por estar próximos a la obsolescencia. Lo anterior se observa en la hoja de flujo de caja de anexo model de planeación financiera XYZ, en la que también están los cronogramas de amortización y de pago de intereses relacionados con el estado de resultados proyectado y el balance general proyectado.

4.3.5. Otros gastos no operacionales

Se proyectaron de la misma forma que en el modelo de corto plazo, es decir, por su estructura.

4.3.6. Capital de trabajo

Se acudió a la misma política en número de días utilizada en el período de corto plazo, pero se tuvieron en cuenta en la proyección los costos y los ingresos proyectados para el largo plazo.

4.3.7. Capex

Solo se contempló una reposición de equipos de cómputo en 2024.

4.4. Construcción del modelo de largo plazo

El modelo se construyó con la misma estructura del de corto plazo y la diferencia radicó en un menor nivel de detalle en el estado de resultados puesto que así se necesita, pues, como se ha planteó en múltiples ocasiones, la otra diferencia significativa se debió a que el modelo pasó de una periodicidad mensual a una anual.

4.5. Resultados de la valoración

Para el ejercicio de la valoración se utilizaron cinco métodos, cuyos resultados se exponen a continuación:

4.5.1. Construcción de los flujos de caja

Tabla 9. Flujo para la valoración

Año	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
FCL	- 4.474.528.002	2.423.865.565	317.453.220	3.056.918.908	3.516.039.859	3.857.163.530	4.044.824.042	4.403.173.194	5.088.449.673	5.774.300.724
FCD	- 31.703.355	- 3.573.516.088	- 2.800.061.503	- 2.351.743.849	- 1.689.604.094	- 1.356.242.671	- 1.093.550.719	- 1.074.072.116	- 726.729.240	- 738.942.030
FCAI	386.284.743	275.291.500	321.689.811	300.944.405	263.171.779	262.856.049	252.186.276	252.842.120	235.501.115	251.720.454
FC Financiación	354.581.388	- 3.298.224.588	- 2.478.371.692	- 2.050.799.444	- 1.426.432.315	- 1.093.386.622	- 841.364.443	- 821.229.996	- 491.228.125	- 487.221.576
FC Accionista	- 4.119.946.614	- 874.359.023	- 2.160.918.473	1.006.119.464	2.089.607.544	2.763.776.908	3.203.459.598	3.581.943.198	4.597.221.547	5.287.079.148
FC Capital	- 4.088.243.259	2.699.157.065	639.143.030	3.357.863.313	3.779.211.638	4.120.019.579	4.297.010.317	4.656.015.314	5.323.950.787	6.026.021.178
FC Capital	- 4.088.243.259	2.699.157.065	639.143.030	3.357.863.313	3.779.211.638	4.120.019.579	4.297.010.317	4.656.015.314	5.323.950.787	6.026.021.178
Kdt	11,91%	7,61%	11,85%	14,24%	16,06%	19,56%	21,75%	24,07%	24,82%	26,65%
Kdt*(1-T)	7,98%	5,10%	7,94%	9,54%	10,76%	13,10%	14,58%	16,13%	16,63%	17,85%

Fuente: elaboración propia

El FCL (flujo de caja libre) provino del flujo el flujo de caja construido para cerrar el balance general.

El FCD (flujo de caja de la deuda) se construyó mediante la siguiente fórmula (ver hoja de deuda actual del anexo model planeación financiera XYZ):

FCD

= *desembolsos – amortizaciones – intereses – otros gastos financieros – diferencia financiera en cambio*

Tabla 10. Flujo de caja de la deuda

Flujo de caja de la deuda	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
Amortización deuda actual	- 1,094,314,522	- 1,910,787,483	- 1,436,527,151	- 1,051,074,362	- 503,397,110	- 321,200,366	- 329,349,883	- 307,883,874	- 13,089,499	- 23,847,225
Intereses	- 1,031,347,424	- 938,438,396	- 840,654,660	- 761,454,372	- 709,237,207	- 677,287,617	- 648,469,171	- 619,901,637	- 606,460,011	- 606,738,757
Otros gastos financieros	- 92,300,409	- 193,399,849	- 74,482,701	- 110,253,961	- 67,444,460	- 115,946,056	- 115,731,665	- 146,286,605	- 107,179,730	- 156,050,498
Desembolsos	2,383,378,914	-	-	-	-	-	-	-	-	-
Amortización deuda nueva	- 150,207,921	- 828,511,938	- 388,716,744	- 388,716,744	- 388,716,744	- 238,508,824	-	-	-	-
Intereses deuda nueva	- 46,911,994	- 89,178,121	- 59,680,247	- 40,244,410	- 20,808,573	- 3,299,808	-	-	-	-
Flujo de caja de la deuda	- 31,703,355	- 3,573,516,088	- 2,800,061,503	- 2,351,743,849	- 1,689,604,094	- 1,356,242,671	- 1,093,550,719	- 1,074,072,116	- 726,729,240	- 738,942,030
Kdt	11.9%	7.6%	11.8%	14.2%	16.1%	19.6%	21.8%	24.1%	24.8%	26.6%
FCAI	386,284,743	275,291,500	321,689,811	300,944,405	263,171,779	262,856,049	252,186,276	252,842,120	235,501,115	251,720,454

Fuente: elaboración propia

El FCAI (flujo de caja del ahorro en impuestos) se obtuvo con la siguiente fórmula:

$$FCAI = (\text{intereses} + \text{otros gastos financieros} + \text{diferencia financiera en cambio}) * \text{tasa nominal de impuesto}$$

El flujo de caja de la financiación se calculó con la siguiente fórmula y también se presentó en la hoja de flujo de caja del anexo model de planeación financiera XYZ.

$$\text{Flujo de caja de la financiación} = FCD + FCAI$$

El FCA (flujo de caja del accionista) se obtuvo con la siguiente fórmula y también se ofreció en la hoja de flujo de caja del anexo model de planeación financiera XYZ:

$$FCA = FCL - \text{flujo de caja de la financiación}$$

El FCC (flujo de caja del capital) se calculó por dos métodos con el fin de garantizar la consistencia en la construcción de los flujos:

$$FCC = -FCD + FCA$$

$$FCC = FCL + FCAI$$

4.5.2. Construcción de las tasas de descuento

Como se observa en la hoja del flujo de caja de la valoración del anexo modelo de planeación financiera XYZ, las tasas se construyeron al comienzo en USD y más tarde, mediante una devaluación proyectada, se pasaron a pesos y su cálculo se efectuó de la siguiente forma:

- **R_f** : rentabilidad de los bonos del Tesoro de Estados Unidos de diez años tomada de Damodaran (2022).
- **$E(R_m)$** : rentabilidad de los mercados de Estados Unidos de los últimos diez años tomada de Damodaran (2022).
- **$E(R_m) - R_f$** : rentabilidad en exceso del mercado.
- **K_{dt}** = $\frac{\text{intereses+otros gastos financieros+diferencia financiera en cambio}}{\text{saldo de la deuda}}$
- **$K_{dt} * (1 - T)$** = costo de la deuda después de impuestos
- **B_d** = $\frac{(K_{dt}-R_f)}{(E(R_m)-R_f)}$. Los modelos de valoración suelen omitir esta variable porque en ellos se supone que en el período inicial es 0.
- **B_l** : se tomó de Damodaran (2022) para el sector al que pertenece la empresa, que no se indicó para proteger su identidad.
- **B_u** = $B_d * \frac{D}{D+K} + B_l * \frac{k}{D+K}$
- **K_u** = $R_f + (E(R_m) - R_f) * B_u$. Rentabilidad exigida por los inversionistas si se supone que la empresa no tiene deuda.
- **K_e** = $R_f + (E(R_m) - R_f) * B_l$. Rentabilidad exigida por los inversionistas.

Tabla 11. Cálculo de las tasas de descuento

USD		COP	
Rf	2,40%	Devaluación	1,60%
E(Rm)	16,40%		
E(Rm) - Rf	14,00%		
Kdt	11,91%		
Kdt*(1-T)	7,98%		
Bd	67,93%		
Bl	0,99		
Bu	0,88		
Ku	14,73%	Ku	16,57%
Ke	16,26%	Ke	18,12%
Ku	14,73%	Ku	16,57%
Ke	16,26%	Ke	18,12%
EMBI	3,64%		
Ku + Riesgo país	18,37%	Ku + Riesgo país	20,27%

Fuente: elaboración propia

Con posterioridad las tasas calculadas se llevaron a su equivalente en COP mediante la utilización de la correspondiente tasa de devaluación. Los cálculos del cuadro anterior corresponden al primer período de valoración. En adelante el mismo cálculo se hizo para cada uno de los restantes períodos de valoración.

Tabla 12. Tasas de descuento Ku por año

Año	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
Deuda	10.969.040.906	8.229.741.486	6.404.497.591	4.964.706.485	4.072.592.631	3.512.883.441	3.183.533.558	2.875.649.684	2.862.560.185	2.886.407.411
Patrimonio	20.320.959.289	21.597.859.528	22.872.347.109	24.306.649.495	26.390.779.770	28.862.871.552	32.359.472.990	36.378.964.240	41.321.234.718	47.024.469.464
Deuda + Patrimonio	31.290.000.195	29.827.601.014	29.276.844.700	29.271.355.980	30.463.372.401	32.375.754.993	35.543.006.548	39.254.613.924	44.183.794.903	49.910.876.875
D/(D+K)	35,1%	27,6%	21,9%	17,0%	13,4%	10,9%	9,0%	7,3%	6,5%	5,8%
K/(D+K)	64,9%	72,4%	78,1%	83,0%	86,6%	89,1%	91,0%	92,7%	93,5%	94,2%
D/K	54,0%	38,1%	28,0%	20,4%	15,4%	12,2%	9,8%	7,9%	6,9%	6,1%
Rf	2,40%	2,40%	2,40%	2,40%	2,40%	2,40%	2,40%	2,40%	2,40%	2,40%
E(Rm)	16,40%	16,40%	16,40%	16,40%	16,40%	16,40%	16,40%	16,40%	16,40%	16,40%
Bl	0,99									
D/K inicial	8,6%									
Bu	0,88									
Ku sin riesgo país	14,73%	14,73%	14,73%	14,73%	14,73%	14,73%	14,73%	14,73%	14,73%	14,73%
Riesgo país puntos	364									
Riesgo país (%)	3,64%									
Ku con riesgo país	18,37%	18,37%	18,37%	18,37%	18,37%	18,37%	18,37%	18,37%	18,37%	18,37%
Devaluación nominal	1,60%	-2,70%	0,00%	1,10%	1,10%	1,10%	1,10%	1,10%	1,10%	1,10%
Ku Cop sin riesgo país	16,57%	11,63%	14,73%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%
Ku Cop con riesgo país	20,27%	15,18%	18,37%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%

Fuente: elaboración propia

4.5.3. Valor terminal

Se calculó el valor terminal con dos escenarios: en el primero no se tomó en cuenta el riesgo de país y en el segundo sí se consideró.

- Se inició por el valor del FCL para 2031 que se obtuvo del FCL proyectado.
- El valor de g se calculó de la siguiente forma:

$$g = PIB \text{ real} + \text{spread}$$

- Se calculó el valor terminal como anualidad perpetua.

$$VT = \frac{FCL \text{ 2031}}{WACC \text{ 2031}}$$

- Y después como crecimiento constante, que fue el valor que se empleó en la valoración.

$$VT = \frac{FCL \text{ 2031} * (1 + g)}{WACC \text{ 2031} - g}$$

Tabla 12. Valor terminal

Valor terminal	Sin riesgo país	Con riesgo país
FCLO 2031	5.774.300.724	5.774.300.724
WACC1 2031	15,49%	19,02%
PIB Real	2,93%	2,93%
Spread	1%	1%
g	3,93%	3,93%
VT (crecimiento constante)	51.888.429.843	39.763.976.001
VT (anualidad perpetua)	37.277.393.879	30.364.841.351

Fuente: elaboración propia

4.5.4. FCC descontado con el Ku

El VPN 1 es el valor de la empresa sin tener en cuenta el riesgo de país y el VPN 2 es el valor de la compañía sin considerarlo.

Tabla 13. FCC descontado a Ku.

FCC a Ku										
Años	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
FCC sin VT	- 4.088.243.259	2.699.157.065	639.143.030	3.357.863.313	3.779.211.638	4.120.019.579	4.297.010.317	4.656.015.314	5.323.950.787	6.026.021.178
VT										51.888.429.843
VP Operaciones 1	30.727.018.723	31.602.773.054	35.619.411.352	37.958.604.497	40.250.585.634	42.568.343.945	45.079.819.494	47.633.981.637	49.928.727.297	51.888.429.843
VT										39.763.976.001
VP Operaciones 2	22.379.279.062	23.076.433.435	26.676.937.153	28.567.570.888	30.408.824.996	32.271.524.772	34.323.706.700	36.420.635.784	38.262.185.231	39.763.976.001
Ku1 sin riesgo país	16,57%	11,63%	14,73%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%
Ku2 con riesgo país	20,27%	15,18%	18,37%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%
VPN 1	26.638.775.464									
VPN 2	18.291.035.803									

Fuente: elaboración propia

4.5.5. FCL descontado con el WACC

Después de calcular VPN descontado con el WACC tradicional se sumó el FCAI en el primer período de la valoración.

Tabla 14. FCC descontado a WACC

FCL a WACC										
Años	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
FCL sin VT	- 4.474.528.002	2.423.865.565	317.453.220	3.056.918.908	3.516.039.859	3.857.163.530	4.044.824.042	4.403.173.194	5.088.449.673	5.774.300.724
VT										51.888.429.843
VP Operaciones 1	30.727.018.723	31.602.773.054	35.619.411.352	37.958.604.497	40.250.585.634	42.568.343.945	45.079.819.494	47.633.981.637	49.928.727.297	51.888.429.843
Wacc tradicional		10,74%	13,71%	15,15%	15,30%	15,34%	15,40%	15,43%	15,50%	15,49%
D%		35,70%	26,04%	17,98%	13,08%	10,12%	8,25%	7,06%	6,04%	5,73%
Kd*(1-T)		5,1%	7,9%	9,5%	10,8%	13,1%	14,6%	16,1%	16,6%	17,9%
K%		64,30%	73,96%	82,02%	86,92%	89,88%	91,75%	92,94%	93,96%	94,27%
Ke		13,87%	15,75%	16,38%	15,98%	15,59%	15,48%	15,38%	15,43%	15,35%
VT										39.763.976.001
VP Operaciones 2	22.379.279.062	23.076.433.435	26.676.937.153	28.567.570.888	30.408.824.996	32.271.524.772	34.323.706.700	36.420.635.784	38.262.185.231	39.763.976.001
Wacc tradicional		13,95%	16,98%	18,55%	18,75%	18,81%	18,89%	18,94%	19,03%	19,02%
D%		49,0%	35,7%	24,0%	17,4%	13,4%	10,9%	9,3%	7,9%	7,5%
Kd*(1-T)		5,1%	7,9%	9,5%	10,8%	13,1%	14,6%	16,1%	16,6%	17,9%
K%		51,0%	64,3%	76,0%	82,6%	86,6%	89,1%	90,7%	92,1%	92,5%
Ke		22,45%	21,99%	21,39%	20,43%	19,69%	19,42%	19,23%	19,23%	19,11%
FCAI	386.284.743									
VPN 1	26.638.775.464									
VPN 2	18.291.035.803									

Fuente: elaboración propia

4.5.6. FCL descontado con el WACC ajustado

Después de calcular el VPN con el WACC ajustado se sumó el FCAI en el primer período de la valoración.

Tabla 15. FCL descontado a WACC ajustado

FCL a WACC ajustado											
Años	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031	
FCL sin VT	- 4.474.528.002	2.423.865.565	317.453.220	3.056.918.908	3.516.039.859	3.857.163.530	4.044.824.042	4.403.173.194	5.088.449.673	5.774.300.724	51.888.429.843
VT											51.888.429.843
VP Operaciones 1	30.727.018.723	31.602.773.054	35.619.411.352	37.958.604.497	40.250.585.634	42.568.343.945	45.079.819.494	47.633.981.637	49.928.727.297	51.888.429.843	51.888.429.843
Wacc ajustado		10,74%	13,71%	15,15%	15,30%	15,34%	15,40%	15,43%	15,50%	15,50%	15,49%
VT											39.763.976.001
VP Operaciones 2	22.379.279.062	23.076.433.435	26.676.937.153	28.567.570.888	30.408.824.996	32.271.524.772	34.323.706.700	36.420.635.784	38.262.185.231	39.763.976.001	39.763.976.001
Wacc ajustado		13,95%	16,98%	18,55%	18,75%	18,81%	18,89%	18,94%	19,03%	19,03%	19,02%
FCAI	386.284.743										
VPN 1	26.638.775.464										
VPN 2	18.291.035.803										

Fuente: elaboración propia

4.5.7. FCA descontado con el Ke

Tabla 16. FCA descontado a Ke

FCA a Ke											
Años	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031	
FCA sin VT	- 4.119.946.614	- 874.359.023	- 2.160.918.473	1.006.119.464	2.089.607.544	2.763.776.908	3.203.459.598	3.581.943.198	4.597.221.547	5.287.079.148	49.002.022.432
VT patrimonial											49.002.022.432
VP patrimonial 1	19.757.977.817	23.373.031.568	29.214.913.761	32.993.898.012	36.177.993.004	39.055.460.503	41.896.285.936	44.758.331.953	47.066.167.112	49.002.022.432	49.002.022.432
Ke		13,87%	15,75%	16,38%	15,98%	15,59%	15,48%	15,38%	15,43%	15,35%	15,35%
Saldo	10.969.040.906	8.229.741.486	6.404.497.591	4.964.706.485	4.072.592.631	3.512.883.441	3.183.533.558	2.875.649.684	2.862.560.185	2.886.407.411	2.886.407.411
VP Operaciones 1	30.727.018.723	31.602.773.054	35.619.411.352	37.958.604.497	40.250.585.634	42.568.343.945	45.079.819.494	47.633.981.637	49.928.727.297	51.888.429.843	51.888.429.843
VT patrimonial											36.877.568.591
VP patrimonial 2	11.410.238.156	14.846.691.949	20.272.439.562	23.602.864.403	26.336.232.365	28.758.641.331	31.140.173.142	33.544.986.101	35.399.625.046	36.877.568.591	36.877.568.591
Ke		22,45%	21,99%	21,39%	20,43%	19,69%	19,42%	19,23%	19,23%	19,11%	19,11%
Saldo	10.969.040.906	8.229.741.486	6.404.497.591	4.964.706.485	4.072.592.631	3.512.883.441	3.183.533.558	2.875.649.684	2.862.560.185	2.886.407.411	2.886.407.411
VP Operaciones 2	22.379.279.062	23.076.433.435	26.676.937.153	28.567.570.888	30.408.824.996	32.271.524.772	34.323.706.700	36.420.635.784	38.262.185.231	39.763.976.001	39.763.976.001
FCD	- 31.703.355										
VPN 1	26.638.775.464										
VPN 2	18.291.035.803										

Fuente: elaboración propia

4.5.8. Valor presente ajustado (APV)

Por último, si se utiliza el valor presente ajustado o APV (forma abreviada que proviene de la expresión en inglés *adjusted present value*) se obtienen el mismo resultado que en los demás modelos garantizando la consistencia de la valoración.

Tabla 17. APV FCL y AI descontados a KU

APV FCL y Al a Ku										
Años	2022	2023	2024	2025	2026	2027	2028	2029	2030	2031
APV										
FCL sin VT	- 4.474.528.002	2.423.865.565	317.453.220	3.056.918.908	3.516.039.859	3.857.163.530	4.044.824.042	4.403.173.194	5.088.449.673	5.774.300.724
VT										51.888.429.843
VP FCL	29.394.643.247	30.390.674.876	34.550.434.350	37.019.597.083	39.424.562.839	41.873.061.076	44.525.517.645	47.243.865.504	49.711.716.142	51.888.429.843
Ku1		11,63%	14,73%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%
FCAI	-	275.291.500	321.689.811	300.944.405	263.171.779	262.856.049	252.186.276	252.842.120	235.501.115	251.720.454
VP AI	1.332.375.476	1.212.098.177	1.068.977.002	939.007.414	826.022.796	695.282.869	554.301.849	390.116.134	217.011.155	
Ku1		11,63%	14,73%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%	15,99%
VP Operaciones 1	30.727.018.723	31.602.773.054	35.619.411.352	37.958.604.497	40.250.585.634	42.568.343.945	45.079.819.494	47.633.981.637	49.928.727.297	51.888.429.843
FCL sin VT	- 4.474.528.002	2.423.865.565	317.453.220	3.056.918.908	3.516.039.859	3.857.163.530	4.044.824.042	4.403.173.194	5.088.449.673	5.774.300.724
VT										39.763.976.001
VP FCL	21.195.547.928	21.988.349.069	25.710.637.645	27.712.103.251	29.648.221.984	31.624.134.593	33.801.133.399	36.048.092.034	38.051.847.270	39.763.976.001
Ku2		15,18%	18,37%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%
FCAI	-	275.291.500	321.689.811	300.944.405	263.171.779	262.856.049	252.186.276	252.842.120	235.501.115	251.720.454
VP AI	1.183.731.134	1.088.084.366	966.299.509	855.467.637	760.603.012	647.390.179	522.573.302	372.543.751	210.337.961	
Ku2		15,18%	18,37%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%	19,67%
VP Operaciones 2	22.379.279.062	23.076.433.435	26.676.937.153	28.567.570.888	30.408.824.996	32.271.524.772	34.323.706.700	36.420.635.784	38.262.185.231	39.763.976.001
VPN1	26.252.490.721									
VPN1	17.904.751.060									

Fuente: elaboración propia

La compañía tiene un valor de entre 6,67 y 9,71 veces su ebitda registrado en 2021, dependiendo de si se utiliza o no el riesgo de país en el ejercicio de valoración.

Capítulo 5: conclusiones y recomendaciones

La elaboración del presente modelo tuvo como objetivo brindar una herramienta de gestión centrada en el valor de la compañía XYZ S. A. Por esta razón, las decisiones planteadas desde el punto de vista estratégico en el corto y en el largo plazo se plasmaron en el modelo de valoración, de tal forma que permitiera identificar los efectos sobre el valor de los planes estratégicos y que obligaban a prever decisiones de financiación para dichas inversiones.

De igual forma, al tener en cuenta que la incertidumbre es inherente a la actividad empresarial, se emplearon las bondades de la inteligencia de negocios para que mediante la ciencia de datos permitiera capturar las variables relevantes del entorno para la compañía con el fin de proyectar y de identificar tendencias que pudieran tener efectos sobre ella; a pesar que se emplearon modelos de aprendizaje automático y de series de tiempo en el momento de presentar los resultados a la gerencia general, fueron los arrojados por la regresión lineal múltiple los de mayor aceptación, no solo por su mayor ajuste estadístico, sino porque marcaron una tendencia encaminada a lo buscado con las inversiones actuales de la firma. Sin embargo, es importante destacar que con todos los modelos utilizados se obtuvieron proyecciones alternativas a las

que la organización puede acudir en cualquier momento y que se incluyeron en las libretas de notas del presente trabajo.

En adelante es importante realizar estudios que se enfoquen en la interacción entre estrategia, planeación financiera e inteligencia de negocios como un mecanismo para lograr círculos virtuosos de gestión desde distintas vertientes de la gestión empresarial, pues, como se planteó a lo largo de todo el trabajo, la estrategia busca establecer la ruta deseada por accionistas y directivos, la planeación financiera se encamina a determinar la viabilidad financiera y el potencial generador de valor de dicha estrategia y la inteligencia de negocios se orienta a que las decisiones tomadas en pro del logro de la estrategia se sustenten en información oportuna y de calidad que permita la generación de valor para cada una de las partes interesadas.

Referencias

Amat Rodrigo, J. (2022, marzo). *Skforecast: forecasting series temporales con Python y Scikit-learn*. Ciencia de Datos, Estadística, Machine Learning y Programación.
<https://www.cienciadedatos.net/documentos/py27-forecasting-series-temporales-python-scikitlearn.html>

Bustos Vargas, J. (2015). *Diseño de un modelo de evaluación y de proyección financiera para la Junta Administradora del Fondo de Ahorro y Préstamo de la Universidad de Costa Rica* [trabajo de grado, Maestría Profesional en Administración y Dirección de Empresas con Énfasis en Finanzas, Universidad de Costa Rica].
<https://www.kerwa.ucr.ac.cr/bitstream/handle/10669/27857/Trabajo%20Final%20de%20Graduaci%c3%b3n%20Jorge%20Bustos%20Vargas%20Carnet%20735005.pdf?sequence=1&isAllowed=y>

- Carrasquilla-Batista, A., Chacón-Rodríguez, A., Núñez-Montero, K., Gómez-Espinoza, O., Valverde, J., y Guerrero-Barrantes, M. (2016). Regresión lineal simple y múltiple: aplicación en la predicción de variables naturales relacionadas con el crecimiento microalgal. *Tecnología en Marcha*, 29, Encuentro de Investigación y Extensión. https://revistas.tec.ac.cr/index.php/tec_marcha/article/view/2983/pdf
- Damodaran, A. (2022, 5 de enero). *Damodaran online. Data*. Stern School of Business, New York University. <https://pages.stern.nyu.edu/~adamodar/>
- Davenport, T., Guszcza, J., Smith, T., & Stiller, B. (2019, 25 de julio). *Analytics and AI-driven enterprises thrive in the age of with the culture catalyst*. Deloitte. <https://www2.deloitte.com/us/en/insights/topics/analytics/insight-driven-organization.htm>
- De la Fuente Fernández, S. (s. f.). *Series temporales, modelo Arima. Metodología de Box-Jenkins*. Departamento de Economía Aplicada, Facultad de Ciencias Económicas y Empresariales, Universidad Autónoma de Madrid. <https://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>
- Deloitte (2013). *CFO insights how CFOs can own analytics*. Deloitte. <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/finance-transformation/us-how-cfos-can-own-analytics-091814.pdf>
- Espino Timón, C. (2017). *Análisis predictivo: técnicas y modelos utilizados y aplicaciones del mismo-Herramientas open source que permiten su uso* [trabajo de grado, Ingeniería Informática, Universitat Oberta de Catalunya]. <https://docplayer.es/52267045-Analisis-predictivo-tecnicas-y-modelos-utilizados-y-aplicaciones-del-mismo-herramientas-open-source-que-permiten-su-uso>

- Espinosa Zúñiga, J. J. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. *Ingeniería Investigación y Tecnología*, 21(3), 1-16. <https://doi.org/10.22201/ifi.25940732e.2020.21.3.022>
- García Serna, Ó. L. (1991). *Valor agregado, flujo de caja y valor de la empresa*. El autor.
- Godet, M. (1995). *De la anticipación a la acción. Manual de prospectiva y estrategia*. Alfaomega-Marcombo.
- Gudivada, V. N. (2017). Chapter 2. Data analytics: Fundamentals. En M. Chowdhury, A. Apon & K. Dey (eds.), *Data analytics for intelligent transportation systems* (pp. 31-67). Elsevier <https://doi.org/10.1016/B978-0-12-809715-1.00002-X>
- Gutiérrez Carmona, J., y Gutiérrez González, D. F. (2018). *Planeación financiera y gestión del valor*. Ecoe Ediciones.
- IBM (s. f.). *¿Qué es deep learning?* IBM. <https://www.ibm.com/co-es/cloud/deep-learning>
- IBM (2021, 17 de agosto). *El modelo de redes neuronales*. IBM. <https://www.ibm.com/docs/es/spss-modeler/SaaS?topic=networks-neural-model>
- Martín del Río, B., y Sanz Molina, A. (1997). *Redes neuronales y sistemas borrosos*. Ra-Ma.
- Martínez González, M., Saavedra García, M. L., y Sánchez Limón, M. L. (2021). Modelo de proyección financiera para el sector construcción. *Lúmina*, 22(1). <https://doi.org/10.30554/lumina.v22.n1.4092.2021>
- Montenegro García, Á. (2010). *Análisis de series de tiempo*. Editorial Pontificia Universidad Javeriana. <https://www-digitaliapublishing-com.ezproxy.eafit.edu.co/visor/19504>
- Porter, M. E. (2011). ¿Qué es la estrategia? *Harvard Business Review América Latina*, 89(11), 100-117. <https://www.ucipfg.com/Repositorio/MAES/MAES-03/Unidad1/ESTRATEGIA%20MPORTER%202011.pdf>
- Rosas Pabón, D. M. (2019). *Diseño de un sistema de pronóstico de la demanda de nitrógeno y oxígeno para la compañía Cryogas, S. A. basado en redes neuronales* [trabajo de

grado, Maestría en Ingeniería, Universidad EAFIT].

<https://repository.eafit.edu.co/handle/10784/7386?locale-attribute=es>

Sassola, C. (2017). *Construcción de un modelo de planificación financiera: Clínica Privada Instituto del Corazón S. R. L., La Rioja* [trabajo de grado, Especialización en Dirección de Finanzas, Universidad Católica de Córdoba].

http://pa.bibdigital.ucc.edu.ar/1603/1/TM_Sassola.pdf

Valle Núñez, A. P. (2020). *La planificación financiera una herramienta clave para el logro de los objetivos empresariales. Revista Universidad y Sociedad*, 12(3), 160-166.

http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S2218-36202020000300160