

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**Colegio de Posgrados**

Integración de modelos cuantitativos y business intelligence para la optimización y planificación financiera: un caso de estudio en una empresa de Software Bancario

Trabajo de investigación y desarrollo**Erik Steven Llerena Duque**

Juan Carlos Chanaba, Ph. D.
Director de Trabajo de Titulación

Trabajo de titulación de posgrado presentado como requisito
para la obtención del título de Máster en Finanzas

Quito, 30 de junio de 2025

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

COLEGIO DE POSGRADOS

HOJA DE APROBACIÓN DE TRABAJO DE TITULACIÓN

Integración de modelos cuantitativos y business intelligence para la optimización y planificación financiera: un caso de estudio en una empresa de Software Bancario

Erik Steven Llerena Duque

Nombre del Director del Programa: Juan José Espinosa de los Monstros

Título académico: MBA

Director del programa de: Escuela de Empresas

Nombre del Decano del colegio Académico: Ana María Novillo

Título académico: Ph. D.

Decano del Colegio: Colegio de Administración de Empresas - CADE

Nombre del Decano del Colegio de Posgrados: Dario Niebieskikwiat

Título académico: Ph. D.

Quito, junio 2025

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombre del estudiante: Erik Steven Llerena Duque

Código de estudiante: 00343024

C.I.: 1727270298

Lugar y fecha: Quito, 30 de junio de 2025.

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

UNPUBLISHED DOCUMENT

Note: The following graduation project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

DEDICATORIA

Con profundo agradecimiento, dedico este trabajo a mis padres, Dr. Stiven Llerena y Ing. Carola Duque, quienes han sido mi mayor inspiración y mi impulso constante. Gracias por enseñarme el valor del esfuerzo, por apoyarme incondicionalmente en cada paso y por creer en mí incluso cuando yo dudaba.

AGRADECIMIENTOS

Quiero agradecer, en primer lugar, a mi familia, mi fuente de poder y refugio en cada etapa de este proceso. Su amor incondicional y apoyo constante han sido el motor que me impulsó a seguir adelante.

A mis profesores, gracias por ser guías invaluables y pilares fundamentales en la construcción de este trabajo; su entrega y conocimiento han dejado una huella imborrable.

Agradezco profundamente a mi gerente general y a mi gerente financiera por confiar en mí, brindarme el espacio para aplicar lo aprendido y acompañarme en este logro.

A mi pareja, gracias por ser mi calma en medio del caos, mi fuerza cuando flaqueé y mi alegría en los días difíciles.

A mis amigos, gracias por ser el abrazo oportuno, la palabra justa y el aliento cuando más lo necesité.

Y a mis hermanos de la maestría, Aarón, Enrique, Martín y Benjamín, gracias por compartir risas, retos y aprendizajes que hicieron de este año una experiencia inolvidable. Este logro es tan mío como de ustedes.

RESUMEN

El presente trabajo analiza cómo la integración de modelos cuantitativos, técnicas de machine learning y herramientas de Business Intelligence pueden optimizar la planificación financiera en una empresa de software bancario. A partir del análisis de datos históricos entre 2019 y 2025, se aplicaron modelos econométricos como VAR, regresión múltiple y LASSO para identificar relaciones causales entre ingresos, costos y eficiencia operativa, con especial énfasis en el área de Servicios Profesionales.

Los resultados demuestran que la implementación de estos modelos permite una toma de decisiones más precisa y estratégica, facilitando la identificación de oportunidades de mejora, la proyección de escenarios y la asignación eficiente de recursos. Este enfoque contribuye al fortalecimiento financiero de la empresa y puede ser replicado en otras organizaciones con contextos similares.

ABSTRACT

This research explores how the integration of quantitative models, machine learning techniques, and Business Intelligence tools can optimize financial planning in a banking software company. Using historical data from 2019 to 2025, econometric models such as VAR, multiple regression, and LASSO were applied to identify causal relationships between revenue, costs, and operational efficiency, with a special focus on the Professional Services area.

The results show that implementing these models enables more accurate and strategic decision-making, helping to identify improvement opportunities, project future scenarios, and allocate resources efficiently. This approach strengthens the company's financial performance and can be replicated in other organizations with similar contexts.

TABLA DE CONTENIDO

CAPÍTULO 1	11
Introducción	11
Planteamiento del problema	12
Propósito del estudio.....	14
Naturaleza del estudio	15
Introducción al Marco Teórico/Conceptual	16
Pregunta de investigación.....	18
El significado del estudio	18
Conclusiones	19
CAPÍTULO 2	20
Revisión de Literatura.....	20
Finanzas corporativas y planificación financiera	20
<i>Finanzas corporativas</i>	20
<i>Planificación Financiera</i>	21
<i>Métricas Financieras Corporativas.....</i>	23
Modelamiento Financiero	25
<i>Definición del modelamiento financiero.....</i>	25
<i>Tipo de modelamientos</i>	26
<i>Modelamiento en la toma de decisiones</i>	27
<i>Modelamiento tradicional o automatizado</i>	27
Análisis Financiero.....	28
<i>Análisis horizontal y vertical</i>	28
<i>Análisis de razones financiera</i>	28
<i>Análisis de variaciones presupuestarias.....</i>	29
<i>Métodos cuantitativos</i>	29
Modelos Econométricos.....	30
<i>Regresión simple y múltiple</i>	31
<i>Modelo ARIMA</i>	31
<i>Modelo VAR</i>	32
<i>Modelo GARCH</i>	33
Machine Learning.....	33
<i>Tipos de aprendizaje</i>	34
<i>Regresión de Lasso</i>	34
Business Intelligence	35
CAPÍTULO 3	36
Enfoque de la investigación.....	36

Diseño de la investigación.....	37
Población y muestra.....	38
Técnica e instrumentos de recolección de datos.....	39
Técnicas de análisis de datos.....	40
Consideraciones éticas	41
Presentación de datos	42
	52
CAPITULO 4	59
Conclusión	59
Recomendaciones del estudio.....	61
Limitaciones del estudio	62
BIBLIOGRAFÍA.....	64
Anexos.....	70

CAPÍTULO 1

Introducción

Con el transcurso del tiempo, la eficiencia operativa y la optimización financiera se han convertido en componentes esenciales para la toma de decisiones a nivel empresarial. En este sentido, gestionar correctamente los recursos financieros no solo se presenta como una tarea obligatoria, sino también como un pilar fundamental para asegurar la sostenibilidad y crecimiento orgánico a largo plazo.

La gestión financiera tradicional enfocada en el análisis estático de resultados y la generación de estados contables se ha quedado obsoleta (Porter, 1985). La constante evolución de tecnologías, como son el análisis computacional masivo de datos, ha generado un mayor uso de herramientas como la inteligencia artificial y business intelligence en la economía y las finanzas. Todo esto con la finalidad de buscar no solo la eficiencia de los recursos propios, sino también en tener capacidad de visualizar previamente escenarios futuros y adaptarse a los desafíos emergentes.

Uno de los principales desafíos radica en lograr la eficacia en la recopilación y análisis de datos para no solo brindar resultados financieros tradicionales, sino también facilitar la toma de decisiones (KPMG International, 2013). En este sentido, una correcta planificación financiera, combinada con análisis detallado de costos e ingresos mediante integración de modelos cuantitativos avanzados, permite a las organizaciones mejorar significativamente en su capacidad estratégica y su rentabilidad financiera.

Además, el uso de técnicas como el análisis de series temporales y la correlación de variables resulta fundamental para comprender el comportamiento en los patrones financieros (Box & Jenkins, 2016). En este sentido, el machine learning se presenta como una herramienta

óptima para identificar patrones claves y realizar predicciones precisas las cuales faciliten la proyección de escenarios optimizando los recursos propios.

Las empresas de tecnología y software, particularmente aquellas que desarrollan soluciones para el sector financiero, enfrentan importantes retos en la gestión eficiente de sus finanzas y en su capacidad para ser competitivas (Prom Peru, 2021). Este es el caso de la empresa, compañía dedicada a la creación y comercialización de software bancario en Latinoamérica y la cual entre sus principales desafíos está la correcta gestión y optimización financiera.

Este trabajo tiene como objetivo principal analizar los factores que contribuyen en el crecimiento, utilizando herramientas financieras para identificar relaciones causales entre variables, las cuales permitan aumentar la rentabilidad de la empresa gestionando de mejor manera los ingresos y costos. Esto mediante la integración de modelos cuantitativos y procesos de aprendizaje autónomo, los cuales ayudarán a reducir el tiempo de respuesta y ayudar a la previsualización de resultados y toma de decisiones.

Planteamiento del problema

El análisis financiero juega un papel de suma importancia en el entorno empresarial, porque no solo se trata de brindar información y gestionar los ingresos y costos, sino más bien porque se ha vuelto en una herramienta que brinda el input necesario para la toma de decisiones. Lograr este objetivo no es fácil para muchas compañías, ya que enfrentan limitaciones en optimizar los recursos y realizar proyecciones buscando la sostenibilidad y crecimiento a lo largo del tiempo.

La empresa fue fundada en 1995 y desde 2019 parte de una multinacional especializada en la creación y comercialización de software bancario en Latinoamérica. Con una cartera de veintidós clientes y cuatro productos estrella, la empresa ha sido considerada como un agente

clave en el desarrollo tecnológico bancario. Sin embargo, uno de los principales desafíos es la correcta planificación y gestión financiera, especialmente por la diversidad de proyectos y contratos con diferentes instituciones financieras, cada uno con sus propias particularidades.

La capacidad de prever con precisión los costos e ingresos es vital no solo para mantener la estabilidad financiera, sino también para que la compañía pueda mantener su liderazgo en el mercado de software bancario (Wasserbacher & Spindler, 2022, p. 75). La información financiera, como estados de resultados, balances, costos de proyectos, y OPEX distribuido, etc, resulta clave para la toma de decisiones. No obstante, estos datos no están siendo explotados completamente para generar proyecciones más precisas y útiles.

Uno de los problemas más significativos es la falta de integración eficiente entre los datos financieros, los métodos cuantitativos avanzados y las herramientas de Business Intelligence (BI) en la planificación financiera y optimización de costos (Spindler., 2022). La ausencia de modelos predictivos robustos, que se basen en datos históricos y análisis avanzados, limita la capacidad de la compañía para identificar oportunidades de mejora y prever de forma certera sus costos y beneficios futuros. Esto repercute directamente en su eficiencia y puede derivar en decisiones imprecisas en la asignación de recursos.

Actualmente, donde la digitalización y el análisis de grandes volúmenes de información son claves, las empresas deben adoptar enfoques basados en modelos cuantitativos y machine learning para mejorar la predicción de costos operativos y optimizar la planificación financiera. Sin embargo, el desafío no radica únicamente en implementar estas herramientas, sino en integrarlas adecuadamente en los procesos financieros y operativos. La falta de una integración efectiva entre los datos financieros y las herramientas avanzadas de análisis implica una pérdida en eficiencia y competitividad.

La falta de integración eficiente de los datos financieros con herramientas tecnológicas representa un obstáculo significativo para el crecimiento de la empresa. Este problema plantea la necesidad de desarrollar un modelo de gestión financiera basada en información y machine learning que permita optimizar la planificación financiera, mejorar la previsión de costos e ingresos, y fortalecer la competitividad en el sector del software bancario a nivel latinoamericano.

Propósito del estudio

El presente estudio y proyecto surge como una oportunidad para impulsar mejoras en la gestión de la empresa, enfocándose en maximizar el uso de datos financieros para la toma de decisiones efectivas. La implementación del análisis de información no solo mejora el entendimiento del negocio y del mercado, más bien, ayuda a identificar oportunidades que mejoren la rentabilidad de la empresa (Mamani, 2018). Además, la implementación de métricas financieras resulta fundamental, para determinar el desempeño de la organización, generando una optimización de recursos.

Los métodos cuantitativos y series financieras han sido ampliamente utilizados en determinar los precios en los mercados de capitales y riesgos en la inversión. Sin embargo, su aplicación en finanzas también ha demostrado su efectividad en la optimización de recursos, contribuyendo al incremento de las utilidades empresariales (Amaya, 2009).

En el contexto actual, el uso de estas metodologías se han vuelto esenciales para las finanzas corporativas, porque, generan una visión más clara de la realidad y enriqueciendo los análisis proyectados. Permitiendo la planificación estratégica, incrementando la rentabilidad, minimizando el riesgo y fortaleciendo el posicionamiento empresarial basado en toma de decisiones basadas en datos lo cual genera una ventaja competitiva en un entorno global cambiante y altamente competitivo.

Naturaleza del estudio

La metodología de investigación del presente trabajo es de carácter deductivo, ya que se partirá de principios generales financieros para determinar las variables principales que tienen influencia causal en los resultados económicos de la compañía. Además, este estudio puede ser catalogado como cuantitativo, dado que se utilizará modelos financieros para establecer la rentabilidad empresarial y realizar modelamientos que busquen la eficiencia futura de las variables estudiadas.

En primer lugar, se utilizará la teoría financiera para identificar las métricas relevantes a estudiar y las variables que las componen. Al comprender las relaciones entre estas variables, se emplearán modelos de series de tiempo, tales como el modelo autorregresivo vectorial (VAR) y ARIMAX, los cuales son útiles para analizar la interrelación entre diferentes variables económicas y determinar cuáles impactan más significativamente en la eficiencia de la empresa (Enders, 2014).

Finalmente, se incorporará machine learning con el fin de generar un modelo financiero que aprenda de los datos históricos y sea capaz de crear escenarios óptimos para la inversión, maximizando el retorno económico. Se utilizarán técnicas avanzadas de machine learning como Random Forest y Lasso, las cuales han demostrado ser eficaces en la predicción de variables financieras y en la identificación de relaciones entre las variables (James, An introduction to statistical learning, 2013).

Los resultados de este análisis serán presentados de manera clara y accesible a través de tableros de Power BI, lo cual facilitará la toma de decisiones, basadas en información y métricas financieras. El software elegido para la manipulación de datos y creación del aprendizaje automático es R, ya que se caracteriza por ser amigable con las diferentes fuentes

de información y las interconexiones que se puedan generar con los servidores de bases de datos y programas para visualizar los modelos.

Introducción al Marco Teórico/Conceptual

Los métodos cuantitativos son herramientas fundamentales en el análisis financiero, ya que facilitan el modelado de datos y proyecciones futuras al identificar y comprender patrones en las variables. Según Hair (2015), estos métodos permiten manejar grandes volúmenes de datos y obtener conclusiones precisas. Su aplicación contribuye a la modelización y optimización financiera, integrando el contexto empresarial con análisis estadísticos y computacionales, lo que resulta en métricas financieras más eficientes y con resultados positivos.

Las métricas financieras son indicadores clave que evalúan la salud y el rendimiento de una empresa. Su uso es esencial para proporcionar información objetiva y comparable con el desempeño de otras empresas o industrias. Entre las métricas más relevantes se encuentran el ROA, ROE y EBITDA, las cuales enriquecen el análisis financiero y sirven como base sólida para determinar el rendimiento y las áreas de mejora en los proyectos, además de sus ratios.

Los ratios financieros, derivados de las métricas financieras, permiten medir y comparar el desempeño empresarial en relación con sus objetivos. De acuerdo con Damodaran (2012), estos ratios actúan como indicadores de diagnóstico para evaluar la estabilidad financiera a corto y largo plazo. Entre los principales se encuentran los ratios de liquidez y endeudamiento; sin embargo, en este caso específico, se emplearán métricas corporativas como el working capital, organic growth y core ratio.

El cumplimiento de los objetivos a largo plazo depende de contar con datos representativos para modelar. La modelización requiere comprender las variables y las series

de tiempo financieras, que son conjuntos de datos recolectados que permiten identificar patrones históricos y proyectar tendencias futuras. Estas series deben incluir información clave sobre variables como costos, gastos e ingresos, sirviendo de base para el análisis cuantitativo. Su implementación permitirá describir la situación actual de la empresa y facilitar la planificación financiera generando resultados positivos y que se alineen con los objetivos corporativos planteados.

Con el uso de machine learning, la modelización de datos se extiende hacia la creación de una inteligencia artificial capaz de aprender de las tendencias y optimizar los resultados (Wasserbacher, H., Spindler, M., 2022). Técnicas como Random Forest y Lasso permiten identificar relaciones complejas entre diversas variables y generar ajustes que cumplan con los objetivos financieros de la empresa.

La aplicación de machine learning desarrolla modelos capaces de prever y adaptarse tanto a factores internos como externos. Esto no solo mejora la capacidad de respuesta ante nuevos retos, sino que también se convierte en un pilar fundamental para alcanzar los objetivos financieros y establecer metas medibles y alcanzables.

La incorporación de estos modelos e inteligencia artificial debe ir acompañada de una cultura orientada a los datos dentro de la organización. Esto implica utilizar herramientas como Business Intelligence (BI), que integran diferentes fuentes de datos y generan reportes automáticos con información precisa y relevante. Este enfoque no solo mejora los procesos, sino que también aporta claridad y precisión en la gestión financiera, optimizando la toma de decisiones de manera rápida y efectiva.

Pregunta de investigación

¿Cómo puede la empresa optimizar su eficiencia financiera y mejorar la planificación de costos e ingresos mediante el uso de modelos cuantitativos y técnicas de Machine Learning, integrados con herramientas de Business Intelligence?

El significado del estudio

El presente trabajo puede considerarse un aporte significativo tanto a la ciencia como a la literatura académica, ya que existen muy pocos estudios en español que aborden la implementación de técnicas de Machine Learning en el ámbito de las finanzas corporativas. Aunque se han desarrollado investigaciones sobre la modelización de riesgos para la detección de fraudes en el sector bancario (Javier Salamanca, 2018) o el análisis de datos aplicados en el mercado financiero (Londoño, 2021), no se dispone de evidencia concreta sobre la aplicación de predicciones automáticas en variables como los ingresos, costos y gastos en una empresa específicamente con fines de optimización financiera.

Asimismo, este estudio aporta al beneficio empresarial al estar enfocado en un caso práctico y de desarrollo aplicado. La compañía se beneficiará directamente de un análisis financiero detallado, de los principales hallazgos obtenidos, y de la creación de una inteligencia artificial financiera destinada a optimizar la toma de decisiones.

Además, el trabajo está alineado con los Objetivos de Desarrollo Sostenible (ODS) propuestos por las Naciones Unidas, específicamente con el ODS número ocho, que busca "promover el crecimiento económico inclusivo y sostenible, el empleo y el trabajo decente para todos" (Naciones Unidas, 2015). Esto se debe a que el estudio tiene como objetivo mejorar la eficiencia económica de la empresa, lo que a su vez puede generar más oportunidades de empleo tanto para hombres como para mujeres en la ciudad de Quito, contribuyendo al desarrollo económico local.

Finalmente, aunque el estudio se centra en un caso específico, su metodología y resultados pueden ser replicados en otras empresas con características similares. Esto permite considerar el trabajo como una base para proyectos a largo plazo en el ámbito financiero corporativo.

Conclusiones

Se puede concluir que la implementación de métodos cuantitativos y business intelligence son efectivos para la toma de decisiones basada en datos históricos. Modelos de series de tiempo los cuales permitirán analizar la incidencia de las variables frente a las métricas financieras permitirán generar modelos predictivos, enfoque que no solo mejora la precisión de las predicciones, sino que también permite explorar escenarios futuros y simular los efectos de decisiones estratégicas, lo que es fundamental para la sostenibilidad y el crecimiento continuo.

CAPÍTULO 2

Revisión de Literatura

Finanzas corporativas y planificación financiera

Finanzas corporativas

Las finanzas corporativas constituyen una rama esencial de la administración financiera donde se estudia “como las empresas asignan sus recursos financieros a proyectos de inversión, como se financian y como devuelven el valor a los accionistas” (Brealey, R. A., Myers, S. C., & Allen, F. , 2019, pág. 9). Este constituye un pilar fundamental para la toma de decisiones sobre la estructura de inversión, financiamiento y gestión eficiente de los recursos financieros.

Analizar la salud económica es clave para la sostenibilidad de una empresa y su capacidad de crecimiento. Desde una visión práctica, el análisis financiero de una empresa se enfoca en resolver las siguientes preguntas: ¿en qué proyecto se debe invertir?, ¿cómo debe financiarse dicha inversión?, y ¿cuál es el rendimiento de la inversión? (Berk, J., & DeMarzo, P., 2005). Estas interrogantes están profundamente ligadas con la toma de decisiones y la evaluación de estrategias que maximicen la rentabilidad y reduzcan el riesgo.

Las finanzas corporativas no son únicamente una herramienta contable o de reporte, sino un marco integral de pensamiento que permite a los directivos crear valor. Mediante el uso de herramientas cuantitativas, modelamiento financiero y métricas claves, se busca prever escenarios futuros y realizar planificaciones estratégicas que permitan abordar problemas complejos como la eficiencia operativa, la planificación de inversiones o la evaluación del desempeño económico (Damodaran, 2012). La gestión financiera permite identificar las fuentes de creación de valor, controlar los riesgos financieros y asegurar que la empresa cuente con los recursos necesarios para operar y crecer.

Planificación Financiera

La planificación financiera permite anticipar la necesidad de recursos a corto y largo plazo. Según Berk y DeMarzo (2020), la planificación cumple un papel estratégico para proyectar los estados financieros futuros y evaluar la viabilidad de proyectos de inversión. De esta manera, las decisiones financieras dejan de ser reactivas e impulsivas, más bien, pasan a estar alineadas con los objetivos de los inversionistas. La estimación de ingreso, egresos y requerimientos de capital permite establecer el camino a seguir para cumplir con las metas propuestas.

Identificar con anticipación los posibles escenarios se vuelve un instrumento esencial para la toma de decisiones estratégicas. La planificación financiera permite a los líderes de las organizaciones vincular las metas operativas con los objetivos financieros, garantizando la coherencia entre las actividades diarias y la visión de la compañía. El ciclo de Financial Planning and Analysis (FP&A) es un conjunto de procesos integrados que permiten planificar, ejecutar y monitorear el desempeño financiero de una empresa. Este ciclo abarca tres fases fundamentales: la elaboración del presupuesto, la generación de pronósticos y el análisis de variaciones (Alexander, 2018).

Alexander (2018), determinó que la primera etapa del ciclo FP&A es el presupuesto, que establece las expectativas financieras anuales de la empresa, incluyendo ingresos, costos, gastos y metas de rentabilidad. La segunda etapa es el forecasting, que consiste en la actualización periódica de proyecciones financieras en función de información más reciente. A diferencia del presupuesto, que se elabora una vez al año, el forecast se realiza con mayor frecuencia (mensual o trimestral), y tiene como propósito ajustar las expectativas y anticipar desviaciones del plan original. Finalmente, el último componente del ciclo FP&A es el análisis

de variaciones, que compara los resultados reales con los presupuestados o proyectados para identificar causas y efectos de las desviaciones.

Los modelos de planificación financiera permiten construir representaciones futuras de los estados financieros y brindar visibilidad de los posibles resultados. Modelos como el proforma, el análisis de escenarios y el rolling forecast son de los tres instrumentos más utilizados dentro de las finanzas corporativas facilitando la toma de decisiones bajo condiciones de incertidumbre (Brigham, E. F., & Houston, J. F., 2019).

Los modelos proforma permiten elaborar proyecciones detalladas de los estados financieros con base en supuestos de crecimiento, márgenes de utilidad y requerimientos de capital, esta herramienta ayuda a simular los impactos financieros de decisiones operativas (El blog de los contadores, 2024). Por otro lado, el análisis de escenarios permite evaluar la sensibilidad de las proyecciones financieras ante cambios en variables claves que pueden generar incertidumbre. Visualizar múltiples futuros posibles, desde uno pesimista hasta uno optimista, y planificar respuestas para cada uno permite la toma de decisiones financieras sobre las condiciones externas e internas del negocio (Damodaran, 2012).

Finalmente, el rolling forecast, complementa al presupuesto tradicional permitiendo actualizaciones periódicas de las proyecciones financieras. Este enfoque mantiene una visión actualizada del desempeño financiero, incorporando datos recientes cada mes o trimestre para extender la previsión hacia adelante (CFI). A diferencia del presupuesto estático, el rolling forecast promueve una cultura de agilidad, adaptación y toma de decisiones en tiempo real. Es especialmente útil en contextos cambiantes, ya que permite reorientar recursos, identificar desviaciones y corregir el rumbo rápidamente. La implementación de esta herramienta requiere una infraestructura de datos sólida la cual permita medir los indicadores financieros mediante métricas claves o indicadores financieros.

Métricas Financieras Corporativas

Las métricas sirven para medir, monitorear y analizar la salud financiera de una empresa u organización. Estos indicadores permiten evaluar si la empresa está cumpliendo sus objetivos estratégicos en términos de rentabilidad, liquidez, eficiencia operativa y solidez financiera (Horngren, C. T., Sundem, G. L., & Elliott, J. A., 2012). La utilización de estas herramientas permite convertir los datos contables en información útil para la toma de decisiones, al ofrecer una representación cuantificable del desempeño, permiten establecer metas, identificar desviaciones y aplicar medidas correctivas.

Uno de los KPIs más importantes y utilizados es el EBITDA (Earnings Before Interest, Taxes, Depreciation, and Amortization). Este indicador permite medir la capacidad operativa de una empresa sin tener en cuenta elementos financieros o contables que pueden distorsionar la rentabilidad real del negocio (Horngren, C. T., Sundem, G. L., & Elliott, J. A., 2012). Es ampliamente utilizado para valorar empresas, analizar flujos de caja potenciales y comparar el desempeño operativo entre compañías o proyectos de inversión.

Si bien este indicador es de uno de los más importantes y conocidos, algunos estudios cuestionan su capacidad para reflejar con precisión la rentabilidad real de una empresa. Penman (2015), por ejemplo, argumenta que el EBITDA puede ser engañoso al excluir costos importantes como depreciación y amortización, los cuales representan gastos reales de desgaste de activos y pérdida de valor.

Al omitir impuestos, intereses y gastos no operativos, este indicador puede sobreestimar la rentabilidad, particularmente en industrias intensivas en capital o con estructuras financieras complejas. No obstante, existe consenso en que su uso debe complementarse con otras métricas financieras para obtener una visión más completa y precisa de la salud financiera de una organización.

El ROE (Return on Equity), o rendimiento sobre el patrimonio, es una de las métricas clave para evaluar la rentabilidad financiera de una empresa desde la perspectiva de los accionistas. Este indicador mide la capacidad de la empresa para generar beneficios con el capital aportado por los propietarios, siendo calculado como el cociente entre la utilidad neta y el patrimonio. Comprender el rendimiento es esencial para valorar la eficiencia en la utilización del capital propio (Berk, J., & DeMarzo, P., 2005).

Por su parte, el ROA (Return on Assets) indica cuán eficientemente una empresa utiliza todos sus activos. Penman (2015), destaca que el ROA es una medida más integral del rendimiento operativo, ya que evalúa el retorno generado sobre todos los recursos disponibles, independientemente de cómo se financiaron. A diferencia del ROE, el ROA es menos sensible a la estructura de capital, lo que lo convierte en una herramienta útil para evaluar la rentabilidad sin el sesgo del apalancamiento.

En el contexto financiero existe un amplio de conjuntos de métricas clave para medir el rendimiento, la liquidez o el riesgo, cada una con distintos enfoques. Damodaran (2012) destacan que indicadores como el margen operativo, el flujo de caja libre y el nivel de endeudamiento son fundamentales para obtener una visión clara del desempeño empresarial. Estas métricas permiten detectar ineficiencias, evaluar la rentabilidad y tomar decisiones informadas que impacten positivamente la gestión financiera.

Desde el enfoque de la planificación financiera, la teoría resalta que estas métricas no solo permiten evaluar resultados históricos, sino que también son fundamentales para proyectar escenarios futuros y realizar ajustes estratégicos. Berk y DeMarzo (2019) señalan que KPIs como el presupuesto ejecutado versus planificado, el EBITDA proyectado y los ratios se utilizan ampliamente en modelos de análisis para anticipar posibles desviaciones y preparar respuestas financieras sólidas.

Modelamiento Financiero

Definición del modelamiento financiero

El modelamiento financiero se entiende como el proceso mediante el cual se construyen representaciones abstractas, de la realidad financiera de una empresa con el fin de analizar su situación económica actual y proyectar su comportamiento futuro. Según Spronk (2011, pág. 229) estos modelos permiten estructurar los estados financieros de forma sistemática, facilitando el análisis de escenarios, la evaluación de riesgos y la toma de decisiones financieras fundamentadas.

Este tipo de modelación resulta esencial en las finanzas corporativas, ya que provee herramientas para evaluar el impacto de distintas decisiones estratégicas como fusiones, adquisiciones, reestructuraciones, o la introducción de nuevos productos o líneas de negocio. Berk y DeMarzo (2005), destacan que el modelamiento financiero se convierte en una extensión de la contabilidad tradicional, al incorporar análisis dinámicos y proyectivos para sustentar decisiones de alto nivel gerencial.

Su implementación dentro de una organización aporta claridad en la planificación y seguimiento financiero, contribuyendo significativamente a la alineación entre los objetivos estratégicos y las capacidades operativas. En ambientes empresariales cada vez más volátiles, el uso de modelos permite anticiparse a problemas financieros y generar acciones correctivas con antelación, como lo evidencian Dayananda, D., Irons, R., Harrison, S., Herbohn, J., & Rowland, P., quienes enfatizan que el modelamiento no solo incrementa la eficiencia, sino que también optimiza la asignación de recursos (2002).

Tipo de modelamientos

Existen diversos tipos de modelos financieros que pueden ser aplicados en función de los objetivos del análisis. Entre los más comunes se encuentran los modelos pro forma, modelos de flujo de caja descontado (DCF), análisis de escenarios, simulaciones Monte Carlo y modelos basados en ratios. Cada uno ofrece una aproximación distinta a la realidad financiera, y su elección depende de la complejidad del entorno empresarial y la disponibilidad de información (Dayananda et al., 2002).

El análisis de flujo de caja descontado (DCF) busca estimar el valor presente de los flujos futuros esperados de una empresa o proyecto, constituyéndose en una herramienta clave para valorar activos y oportunidades de inversión (Damodaran, 2012). Complementariamente, los análisis de escenarios y sensibilidad permiten estudiar cómo variaciones en ciertas variables clave afectan los resultados financieros, lo que es esencial en contextos de incertidumbre.

Estos enfoques no están exentos de críticas. Algunos académicos como Taleb (2007), argumentan que los modelos financieros, especialmente aquellos que dependen fuertemente de supuestos lineales o deterministas, pueden inducir a errores sistemáticos en entornos inciertos. Asimismo, autores como Derman (2011), destacan que el exceso de confianza en la modelación matemática puede llevar a una ilusión de certeza, ignorando eventos de atípicos o shocks externos que no pueden preverse mediante una hoja de cálculo convencional.

Además, la rigidez inherente de algunos modelos financieros tradicionales ha sido señalada como una de sus principales limitaciones. Estudios sostienen que la estandarización excesiva de modelos reduce su capacidad de adaptarse a realidades dinámicas y específicas de cada industria (Power, 2008). En este sentido, es importante entender que los modelos deben ser herramientas de apoyo, no sustitutos del juicio financiero profesional.

Modelamiento en la toma de decisiones

En el contexto de la toma de decisiones empresariales, el modelamiento financiero actúa como una guía cuantitativa para evaluar múltiples cursos de acción. Su aplicación no solo permite comparar opciones estratégicas, sino también entender la sensibilidad de los resultados frente a variables críticas como tasas de interés, inflación o precios de insumos. Según Fabozzi, Focardi y Kolm (2012), la principal ventaja de los modelos financieros radica en su capacidad de estructurar escenarios y utilizar la información pasada para predecir el futuro.

Para que un modelo financiero sea efectivo, debe cumplir con principios fundamentales como claridad, coherencia, transparencia y auditabilidad. Las mejores prácticas incluyen documentar los supuestos utilizados, separar claramente las entradas, cálculos e informes, y evitar estructuras de fórmula demasiado complejas que dificulten su entendimiento (Frank J. Fabozzi, Sergio M. Focardi, Petter N. Kolm, 2012). Asimismo, es clave validar constantemente los modelos con datos reales y ajustar los supuestos a medida que se disponga de mejor información.

Modelamiento tradicional o automatizado

La evolución tecnológica ha impulsado el desarrollo de modelos automatizados mediante software especializado y herramientas de Business Intelligence (BI). A diferencia del modelamiento tradicional, que depende de hojas de cálculo estáticas, los modelos automatizados integran datos en tiempo real y pueden actualizarse dinámicamente. Según un estudio de Forbes (2024), las empresas que migraron hacia sistemas financieros automatizados experimentaron mejoras sustanciales en la agilidad de la planificación.

Sin embargo, no todos los autores coinciden en su efectividad. Saeed (2021), indica que la automatización puede generar una excesiva dependencia de algoritmos sin supervisión crítica, afectando la calidad del análisis si no se acompañan de criterio financiero experto.

No obstante, hay casos documentados como el de Coca-Cola (Harvard Business Review, 2018), donde la automatización de modelos financieros redujo el ciclo de presupuestación en un 40%, lo cual muestra su aplicabilidad exitosa bajo una correcta implementación.

Análisis Financiero

Análisis horizontal y vertical

El análisis financiero horizontal y vertical son herramientas fundamentales para interpretar los estados financieros. El análisis horizontal permite evaluar las variaciones absolutas y relativas en los estados financieros a lo largo del tiempo, identificando tendencias, patrones y cambios estructurales en ingresos, costos, activos y pasivos. Este tipo de análisis ayuda a detectar movimientos significativos en las cifras contables que pueden indicar oportunidades o riesgos financieros emergentes (Fraser, L. M., & Ormiston, A. , 2015).

Por otro lado, el análisis vertical se enfoca en la evaluación de la estructura interna de los estados financieros dentro de un mismo periodo, al representar cada partida como un porcentaje de una cifra base, como el total de activos en el balance general o los ingresos en el estado de resultados. Esto permite comparar eficiencias relativas, como el peso de los costos operativos o la proporción de pasivos frente al total de activos (Fraser, L. M., & Ormiston, A. , 2015).

Análisis de razones financieras

El análisis de razones financieras permite evaluar el desempeño de una empresa mediante indicadores que relacionan diversas partidas de los estados financieros. Según Damodaran (2012), estas razones se agrupan en categorías como liquidez, rentabilidad, endeudamiento y eficiencia operativa. Son útiles para comparaciones intertemporales e

interempresariales, sirviendo como insumo clave para decisiones estratégicas, evaluaciones de desempeño y alertas tempranas sobre potenciales desequilibrios financieros.

Análisis de variaciones presupuestarias

El análisis de variaciones presupuestarias consiste en comparar los resultados reales con los presupuestados, identificando diferencias y sus causas. Este análisis no solo mide el grado de cumplimiento del plan financiero, sino que también permite retroalimentar los procesos de planificación y control. Además, este análisis contribuye a mejorar el pronóstico financiero, ajustando proyecciones futuras en base al comportamiento histórico y a la precisión de estimaciones anteriores.

Así, se convierte en una herramienta dinámica que no solo evalúa el pasado, sino que también fortalece la capacidad predictiva y de adaptación de la organización. Autores como Anthony y Govidaranjan (2012), destacan que las variaciones deben analizarse considerando factores internos y externos, para establecer si son atribuibles a fallas de gestión o a condiciones cambiantes del entorno.

Métodos cuantitativos

Los métodos cuantitativos en finanzas corporativas se refieren al uso de herramientas estadísticas y matemáticas para analizar información financiera y tomar decisiones fundamentadas. Estos métodos permiten identificar relaciones entre variables, proyectar resultados futuros y optimizar la asignación de recursos (Damodaran, 2012). El enfoque cuantitativo es esencial para sustentar hipótesis con evidencia numérica y para desarrollar modelos predictivos sólidos. El uso de regresiones, análisis de varianza, modelos econométricos y simulaciones son ejemplos comunes en el ámbito financiero. Estas técnicas permiten, por ejemplo, evaluar cómo ciertas variables explicativas como el costo de ventas o el gasto operativo afectan el margen de utilidad o el EBITDA.

Entre las técnicas más comunes se encuentran la regresión lineal, los modelos ARIMA, VAR, GARCH y el análisis de series temporales, los cuales permiten modelar relaciones entre variables financieras, prever escenarios futuros y tomar decisiones fundamentadas en datos. Estos modelos son particularmente útiles para evaluar el comportamiento de indicadores clave como el flujo de caja, el retorno sobre activos (ROA) o el costo de capital. Como mencionan Hill, et al. (2018), el uso de modelos estadísticos en finanzas permite aislar efectos, identificar correlaciones y medir el impacto de las decisiones financieras en entornos complejos.

Diversos estudios y casos reales han aplicado estos enfoques con resultados significativos. Por ejemplo, el trabajo de Tsay (2005), mostró cómo modelos ARIMA y GARCH son eficaces para predecir la volatilidad de ingresos en empresas multinacionales, facilitando una mejor asignación de recursos. En otro caso, un estudio de El-Sayed (2009), utilizó análisis de regresión para explorar el impacto del apalancamiento financiero sobre la rentabilidad de empresas egipcias, concluyendo que existe una relación negativa significativa en ciertos sectores.

Por su parte, la investigación de Bali, T. G., Cakici, N., & Whitelaw, R. F (2011), utilizó modelos cuantitativos para evaluar la relación entre el riesgo idiosincrático y los rendimientos accionarios en el mercado de capitales estadounidense, empleando técnicas de series temporales y regresión multivariada. Estos estudios evidencian cómo los métodos cuantitativos fortalecen el análisis financiero y la toma de decisiones en contextos reales y diversos, tanto en el ámbito corporativo como en los mercados financieros.

Modelos Econométricos

Los modelos econométricos clásicos, como regresiones simples y múltiples, el modelo VAR (Vector Autoregressive), ARIMA o GARCH, son herramientas utilizadas para modelar y prever variables económicas y financieras. Estos modelos capturan dinámicas temporales,

autocorrelaciones y, en algunos casos, volatilidad, lo que los hace útiles para prever ingresos, tasas de interés o rentabilidad de activos financieros (Hill, R. C., Griffiths, W. E., & Lim, G. C., 2018).

Regresión simple y múltiple.

La regresión lineal simple es un método estadístico que modela la relación entre una variable dependiente y una independiente, permitiendo estimar cómo un cambio en la variable explicativa afecta a la variable de interés (Enders, 2014). Es ampliamente utilizada para predecir variables financieras como ingresos o costos, en función de un solo factor, como el volumen de ventas o el precio de mercado.

Por su parte, la regresión lineal múltiple amplía este enfoque al incluir varias variables independientes. Esta técnica es útil para modelar fenómenos financieros más complejos, donde múltiples factores pueden influir simultáneamente en una métrica clave (Enders, 2014). Por ejemplo, el ROE podría depender del apalancamiento financiero, la eficiencia operativa y la rotación de activos.

Modelo ARIMA

El modelo ARIMA (Autoregressive Integrated Moving Average) es una herramienta estadística ampliamente utilizada para analizar y predecir series temporales financieras, especialmente cuando los datos presentan tendencias o no son estacionarios. Este modelo combina tres componentes: autorregresión (AR), diferencia integrada (I), y media móvil (MA), permitiendo capturar patrones pasados para proyectar comportamientos futuros (Lütkepohl, 2006).

Según Time Series Analysis and Its Applications de Shumway y Stoffer (2017), ARIMA ha sido una técnica clave en el pronóstico financiero debido a su precisión en contextos

donde la estacionalidad y la tendencia pueden ser modeladas de manera explícita. Por ejemplo, en el estudio de Zhang (2003) se evaluó su eficacia frente a redes neuronales para predecir el mercado bursátil, destacando que ARIMA funciona bien cuando los patrones lineales predominan.

Modelo VAR

El modelo VAR (Vector Autoregressive) es ideal para analizar interacciones dinámicas entre múltiples variables económicas o financieras. A diferencia de ARIMA, que se centra en una sola variable, el VAR permite modelar un conjunto de series de tiempo que se influencian mutuamente, lo cual es especialmente útil para entender la relación entre indicadores financieros como los ingresos, gastos y patrimonio. El modelo no requiere una estricta formulación estructural, lo que facilita su uso cuando las relaciones entre variables no están claramente definidas (Londoño, W., 2005).

Una de las grandes virtudes del VAR es su capacidad para generar funciones de impulso-respuesta y descomposición de varianza, que permiten observar cómo un shock en una variable afecta a las demás a lo largo del tiempo. Esto es particularmente relevante en la planificación financiera y en la gestión de riesgos. Sims (1980), uno de los principales impulsores de este modelo, argumentó que los VAR ofrecen una forma empírica sólida de capturar relaciones económicas sin imponer restricciones teóricas arbitrarias.

En finanzas corporativas, su uso ha sido validado en estudios Kim, Kim y Lee (2020) emplearon modelos VAR para estimar cómo shocks macroeconómicos afectan la estructura financiera de empresas coreanas, mostrando que el VAR es fundamental para anticipar impactos y fortalecer la resiliencia financiera.

A pesar de su popularidad en el análisis financiero y macroeconómico, algunos estudios cuestionan la eficacia del modelo VAR en contextos financieros complejos. Por ejemplo, Faust y Leeper (1997) señalan que la identificación estructural en modelos VAR puede ser ambigua y sensible a supuestos arbitrarios, lo cual limita su capacidad para ofrecer inferencias causales sólidas en mercados volátiles.

Asimismo, Canova y Pina (1993) advierten que los modelos VAR tradicionales pueden subestimar las relaciones dinámicas no lineales entre variables financieras, especialmente durante períodos de crisis o alta incertidumbre, donde los efectos de los choques pueden cambiar de forma significativa.

Modelo GARCH

El modelo GARCH, desarrollado por Bollerslev (1986), está diseñado para capturar la volatilidad cambiante en series temporales financieras. Específicamente, GARCH permite modelar la varianza condicional de un activo a lo largo del tiempo, siendo ideal para analizar datos financieros con alta frecuencia, como precios de acciones o rendimientos diarios, donde los niveles de riesgo varían constantemente. Su principal virtud es modelar "clusters" de volatilidad, es decir, períodos donde la varianza se agrupa, lo cual es común en mercados financieros.

Machine Learning

El Machine Learning (ML) es una subdisciplina de la inteligencia artificial que permite a los sistemas aprender automáticamente a partir de datos, identificar patrones y tomar decisiones con mínima intervención humana. Un programa aprende de una experiencia E con respecto a una tarea T (Mitchell, 1997). En el contexto financiero, ML se utiliza para modelar riesgos, prever precios de activos, optimizar portafolios y detectar fraudes, debido a su capacidad para manejar grandes volúmenes de datos con relaciones no lineales y complejas.

Tipos de aprendizaje

El aprendizaje supervisado es el más común y consiste en entrenar algoritmos con un conjunto de datos que contiene entradas y salidas conocidas. Modelos como la regresión lineal, árboles de decisión y redes neuronales utilizan este enfoque para predecir variables cuantitativas o clasificar eventos. En finanzas, se usa para predecir precios, niveles de riesgo crediticio o probabilidad de incumplimiento, dado un conjunto de características históricas (James, 2013).

El aprendizaje no supervisado, por otro lado, no tiene variables objetivo definidas. El sistema intenta identificar patrones o agrupaciones en los datos. Este tipo es útil en análisis financiero para segmentar clientes, encontrar anomalías en los gastos o evaluar relaciones latentes entre activos financieros. Algoritmos como k-means clustering o PCA (Análisis de Componentes Principales) son ejemplos comunes de este enfoque (James, 2013).

Finalmente, el aprendizaje por refuerzo se basa en un agente que interactúa con un entorno y aprende a maximizar una recompensa a través de prueba y error. Aunque es menos común en análisis financiero tradicional, ha ganado tracción en la automatización del trading, donde el sistema aprende políticas óptimas de inversión en entornos volátiles (Sutton, 2018).

Regresión de Lasso

La regresión LASSO (Least Absolute Shrinkage and Selection Operator) es una técnica de regularización que mejora la precisión del modelo reduciendo el sobreajuste y realizando selección automática de variables (Tibshirani, 1996).

En finanzas, LASSO ha sido aplicado para seleccionar factores clave en el análisis de rentabilidad o para identificar variables significativas que afectan el desempeño financiero. Por ejemplo, De Prado (2018) utilizó LASSO para seleccionar factores relevantes en modelos

multifactoriales para predicción de retornos bursátiles, mejorando la eficiencia y la interpretabilidad del modelo. Otro caso fue el estudio de Zhang et al. (2020) que utilizó LASSO para seleccionar determinantes clave del riesgo de crédito en portafolios bancarios con grandes volúmenes de datos financieros históricos.

Business Intelligence

Business Intelligence (BI) se refiere al conjunto de herramientas, tecnologías y metodologías que permiten transformar datos en información útil para la toma de decisiones estratégicas. BI comprende procesos para recopilar, integrar, analizar y presentar información empresarial que permite a los gestores identificar oportunidades, tendencias y patrones de comportamiento (Turban, E., Sharda, R., Delen, D., & King, D., 2011). Su objetivo no es solo visualizar información, sino apoyar una gestión más ágil y basada en evidencia, a través de cuadros de mando, reportes interactivos y sistemas de soporte a decisiones.

En el ámbito financiero, BI se emplea para automatizar la consolidación de estados financieros, analizar KPIs como EBITDA o ROE en tiempo real, y generar alertas de desviaciones presupuestarias. Herramientas como Power BI, Tableau o Qlik se integran fácilmente con sistemas contables y ERPs, facilitando el monitoreo continuo del desempeño económico. La integración de BI con modelos cuantitativos y Machine Learning eleva su valor, al permitir no solo analizar el pasado, sino proyectar el futuro. Por ejemplo, se pueden incorporar modelos de regresión, predicción de flujo de caja o clasificación de riesgo dentro de dashboards dinámicos, permitiendo a los analistas tomar decisiones predictivas y prescriptivas de forma visual, rápida y confiable.

CAPÍTULO 3

Enfoque de la investigación

La presente investigación adopta un enfoque cuantitativo, dado que se orienta al análisis numérico y estadístico de información financiera histórica de la empresa. A través de este enfoque se pretende identificar patrones, relaciones y proyecciones en variables financieras clave, utilizando modelos matemáticos y técnicas de predicción, lo cual permitirá una evaluación objetiva y medible del desempeño económico-financiero de la organización.

El enfoque cuantitativo se justifica en la necesidad de utilizar técnicas de análisis empírico que respalden las decisiones estratégicas con evidencia. Según Hernández, el método cuantitativo “utiliza la recolección y el análisis de datos para contestar preguntas de investigación y probar hipótesis previamente establecidas, basándose en la medición numérica y el uso de estadística” (2014). Dado que el presente estudio emplea herramientas como modelos de series de tiempo, regresiones múltiples y algoritmos de machine learning, el análisis cuantitativo es el más adecuado para examinar relaciones entre variables como el EBITDA, OPEX y ratios financieros.

El uso de indicadores financieros, junto con técnicas de predicción y visualización de datos, respalda la necesidad de operar desde un paradigma basado en la medición y la precisión estadística. Este estudio se fundamenta precisamente en esas metas, pues busca comparar resultados financieros, identificar tendencias en el comportamiento histórico y generar proyecciones que contribuyan a una mejor toma de decisiones financieras en escenarios futuros.

Diseño de la investigación

La investigación puede ser clasificada como exploratoria, correlacional y experimental. Es exploratoria porque busca profundizar en el entendimiento del uso de técnicas de modelamiento financiero avanzadas, como las series de tiempo y algoritmos de Machine Learning, en contextos corporativos. Esta fase exploratoria permite identificar patrones, relaciones y tendencias en datos financieros históricos, lo que brinda una base para el análisis posterior.

Asimismo, se considera correlacional, ya que se busca determinar el grado de relación entre diferentes variables financieras frente a los ratios de rentabilidad y otros KPI's. Esto permitirá establecer vínculos significativos entre las métricas tradicionales y las proyectadas por modelos automatizados. Finalmente, también se categoriza como experimental, ya que se realizarán pruebas empíricas mediante el entrenamiento y evaluación de modelos predictivos sobre datos financieros.

El diseño de este estudio es de tipo cuantitativo longitudinal, ya que se trabajará con datos históricos de estados financieros de empresas para construir modelos predictivos, identificando cambios en el tiempo y proyectando futuros escenarios. Además, es un diseño aplicado, puesto que se orienta hacia la resolución de problemas prácticos dentro de la gestión financiera empresarial.

Desde la perspectiva teórica, el enfoque adoptado se sustenta en el paradigma práctico, que busca explicar la realidad financiera mediante la observación empírica y la medición objetiva de datos. Según Creswell (2014), el enfoque cuantitativo permite generalizar resultados a partir del análisis estadístico, lo cual es coherente con el uso de modelos como VAR o LASSO, que se basan en principios de inferencia matemática.

Población y muestra

La población está constituida exclusivamente por la empresa, organización destacada en el desarrollo de soluciones tecnológicas para el sector financiero a nivel latinoamericano. Al ser una compañía con una sólida trayectoria desde 1992 hasta la actualidad en la industria de software bancario, sus operaciones representan un caso de estudio relevante para examinar la eficiencia financiera mediante modelos cuantitativos y herramientas de análisis predictivo.

La elección de la empresa como unidad de análisis responde a su representatividad en el mercado y al acceso continuo y confiable a sus registros contables, lo que permite una observación sistemática del comportamiento financiero en un entorno corporativo especializado.

La muestra corresponde a la totalidad de los datos financieros mensuales de la compañía comprendidos entre junio de 2019 y mayo del 2025. Se tomarán variables clave como ingresos operativos, costos de las 4 áreas principales de la empresa y que tienen efectos directamente con EBITDA, utilidad neta y entre otros indicadores financieros que permiten evaluar el desempeño empresarial y construir modelos de predicción.

Debido a que se dispone de información completa y consistente para el período señalado, no se aplicarán criterios de inclusión ni exclusión, ya que se utilizará la totalidad del conjunto de datos disponible. Este enfoque permitirá captar con mayor precisión las dinámicas internas de la empresa asegurando un análisis integral y representativo de su comportamiento financiero. Además, al trabajar con toda la base de datos, se minimiza el riesgo de sesgos y se fortalece la robustez estadística de los modelos empleados.

Técnica e instrumentos de recolección de datos

En esta investigación se empleó una técnica de análisis documental aplicada específicamente a la revisión de los informes financieros mensuales presentados por la empresa durante el período comprendido. Esta técnica permitió realizar una evaluación sistemática de los estados financieros, los cuales constituyen la base empírica sobre la que se desarrollaron los modelos cuantitativos y el análisis posterior.

Dado que la empresa emite reportes financieros de manera mensual, fue posible acceder a una base de datos histórica estructurada y continua, lo que facilitó el análisis de tendencias, proyecciones y relaciones entre variables clave del desempeño financiero. Los instrumentos utilizados fueron los balances generales, estados de resultados, reportes mensuales internos y demás informes enviados al corporativo. Estos documentos contables proporcionan información detallada sobre ingresos, costos, gastos operativos, activos, pasivos y capital contable, lo cual resulta indispensable para el modelamiento.

En cuanto al procedimiento, se inició con la recopilación de los estados financieros emitidos mensualmente por el área contable. Posteriormente, se procedió a la extracción y sistematización de la información contenida en los estados de resultados, segmentando los datos por fecha, por área de operación y por tipo de gasto. Esta segregación permitió organizar la información en estructuras matriciales adecuadas para su posterior análisis mediante herramientas estadísticas, modelamiento financiero y algoritmos de aprendizaje automático.

Una vez organizada la base de datos, se integró en hojas de cálculo y software especializado para el tratamiento cuantitativo y la simulación de escenarios, de acuerdo con los objetivos de la investigación.

Técnicas de análisis de datos

La presente investigación adoptó un enfoque cuantitativo respaldado por una secuencia estructurada de técnicas de análisis de datos financieros. El proceso se inició con la extracción de la información contable desde los informes financieros mensuales de la empresa, la cual fue transferida y organizada en hojas de cálculo. Esta etapa inicial permitió una primera revisión visual de los datos, donde se identificaron posibles inconsistencias, se validó la integridad de la información y se realizaron las correspondientes modificaciones, depuraciones y clasificaciones necesarias para preparar los datos para su análisis más avanzado.

Posteriormente, la información procesada fue cargada en el entorno estadístico R, herramienta que facilitó el tratamiento, limpieza y estructuración temporal de los datos para su posterior análisis. En esta fase se aplicaron modelos de series de tiempo, lo cual permitió comprender la dinámica y evolución de las principales variables financieras a lo largo del período observado. El análisis en R incluyó la identificación de estacionalidades, tendencias y posibles correlaciones entre variables. Estas relaciones fueron fundamentales para preparar los insumos para los modelos predictivos posteriores.

Finalmente, se empleó el lenguaje de programación como herramienta principal para la construcción de modelamiento financiero automatizado y de aprendizaje automático (machine learning). El software ofreció ventajas significativas por su robustez, escalabilidad y las múltiples bibliotecas especializadas que facilitaron la implementación de algoritmos para la predicción de métricas financieras.

Esta última fase permitió simular escenarios futuros, evaluar el impacto de cambios en variables clave y proponer mejoras basadas en datos objetivos. Esto otorgó a la investigación una capacidad analítica robusta para respaldar la toma de decisiones estratégicas con evidencia cuantitativa confiable.

Consideraciones éticas

Dado el uso de datos reales provenientes de una empresa legalmente constituida, se ha tomado la decisión de mantener en reserva el nombre de la organización como medida de respeto, confidencialidad y resguardo institucional. Adicionalmente, se mantuvo una conversación directa con el Gerente General, la Gerente Financiera y la responsable del área de Talento Humano, con quienes se revisó la naturaleza del proyecto y el tratamiento confidencial de los datos. Tras el análisis y validación del enfoque metodológico, se otorgó la aprobación formal para el uso de la información bajo los lineamientos acordados.

Con el objetivo de proteger aún más la información sensible, los datos fueron tratados mediante técnicas de anonimización, tales como la transformación de las series mediante multiplicación o división por factores aleatorios. Esta estrategia permite preservar las relaciones estadísticas y estructurales entre las variables, sin comprometer los valores reales o la integridad confidencial de la información original.

Este proyecto de investigación se enmarca en un acuerdo de confidencialidad (NDA, por sus siglas en inglés), el cual fue debidamente firmado por ambas partes. En este acuerdo se autoriza el uso de los datos únicamente con fines académicos, prohibiendo expresamente su divulgación o reutilización con otros fines no investigativos.

De igual forma, se ha garantizado en todo momento que el tratamiento, análisis y presentación de los resultados se realice con integridad científica y rigor metodológico, sin inducir interpretaciones erróneas ni forzar conclusiones que puedan comprometer el sentido ético del estudio. Este compromiso busca no solo proteger los intereses de la empresa colaboradora, sino también mantener los más altos estándares académicos.

Presentación de datos

La presente sección tiene como propósito exponer y analizar los datos financieros procesados, permitiendo una comprensión integral del comportamiento de las variables a lo largo del tiempo. A partir de las series históricas disponibles, se ha estructurado la información en función de la naturaleza de las cuentas, área operativa y períodos mensuales, facilitando así la identificación de patrones, estacionalidades y posibles irregularidades.

Este análisis inicial es clave para comprender el contexto financiero de la empresa y establecer las bases para la posterior aplicación de modelos econométricos y de predicción. A través de gráficos, estadísticas descriptivas y segmentación por unidades de negocio, se busca revelar dinámicas clave que impactan la eficiencia financiera, apoyando así un diagnóstico más preciso y una mejor toma de decisiones estratégicas.

Esta sección se estructura siguiendo un enfoque top-down: comienza con la exploración preliminar de los datos financieros, continúa con la identificación y análisis de las variables de mayor impacto, y culmina con la presentación de los modelos predictivos desarrollados. Esta secuencia metodológica brinda una base sólida para la interpretación de los hallazgos expuestos al final del trabajo.

La base de datos inicial contempla las distintas fuentes de generación económica de la empresa, los costos directos asociados y el resultado neto histórico, todo extraído del sistema contable. Para garantizar la confidencialidad de la información, los valores fueron transformados mediante un factor aleatorio, manteniendo las proporciones relativas entre variables. Asimismo, se reemplazaron los datos faltantes por ceros, con el fin de preservar la estructura del conjunto de datos sin afectar las correlaciones ni el desempeño de los modelos predictivos desarrollados posteriormente.

La Tabla 1 presenta un resumen de los valores que forman la matriz de datos utilizada en este análisis. El conjunto contempla 8 variables, detalladas en la Tabla 2, y un total de setenta y dos observaciones correspondientes al período evaluado. Entre las variables se incluyen los tres tipos de ingresos: “Ingresos Profesionales”, “Ingresos por Mantenimiento” e “Ingresos por Licencia”. A continuación, se registran los costos asociados a cada tipo de ingreso y, finalmente, el “Ingreso Neto”, calculado como la diferencia entre los ingresos totales y los costos directos correspondientes.

Tabla 1. Ingresos por tipo de servicio

Professional Revenue	Maintenance and Warranty Revenue
174056.2	323106.9
387645.2	335762.3
268240.5	335769.6
328449.2	318407.1
214485.1	319275.9
145842.3	340907.3

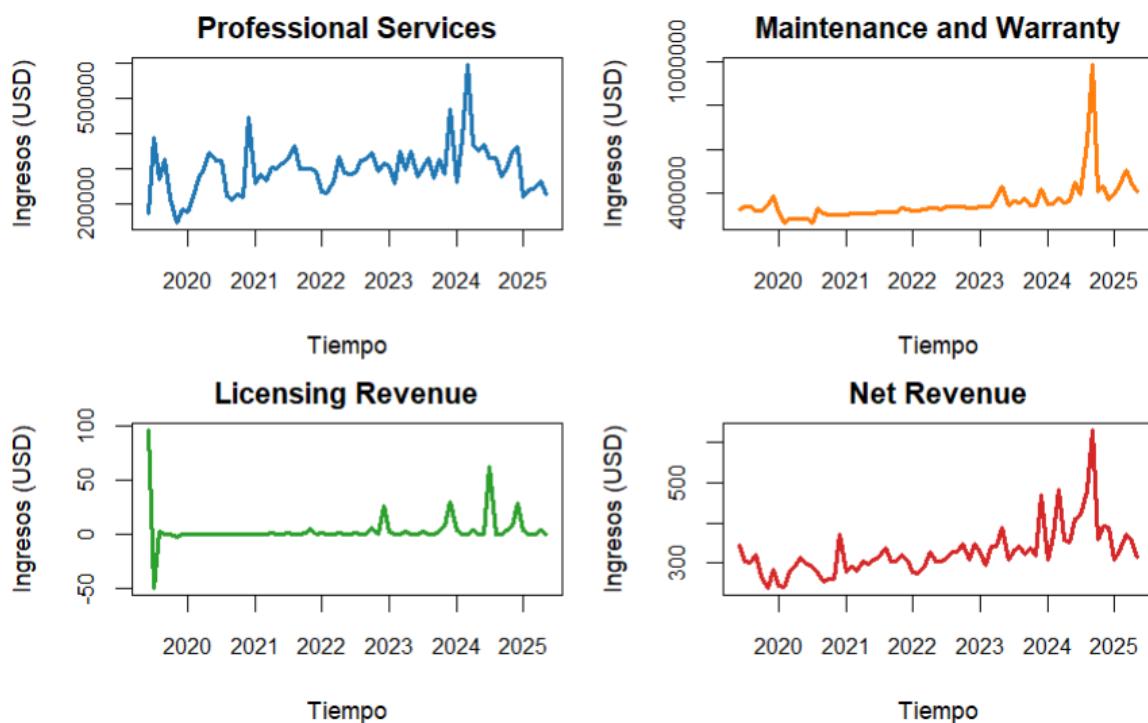
Fuente: Estado de resultados de la empresa
Elaboración: Propia / Software R

Tabla 2. Ingresos por tipo de servicio

Nombre de la variable	Descripción
License Revenue	Ingresaos por licenciamiento inicial
Professional Revenue	Ingresaos por desarrollos
Maintenance and Warranty Revenue	Ingresaos por licencia recurrente
Gross Revenue	Ingresaos Brutos
Professional COGS	Costos directos asociados a desarrollos
Maintenance COGS	Costos directos asociados a la licencia recurrente
Net Revenue	Ingresaos Netos

Elaboración: Propia

Gráfico 1: Evolución histórica de las variables de ingresos

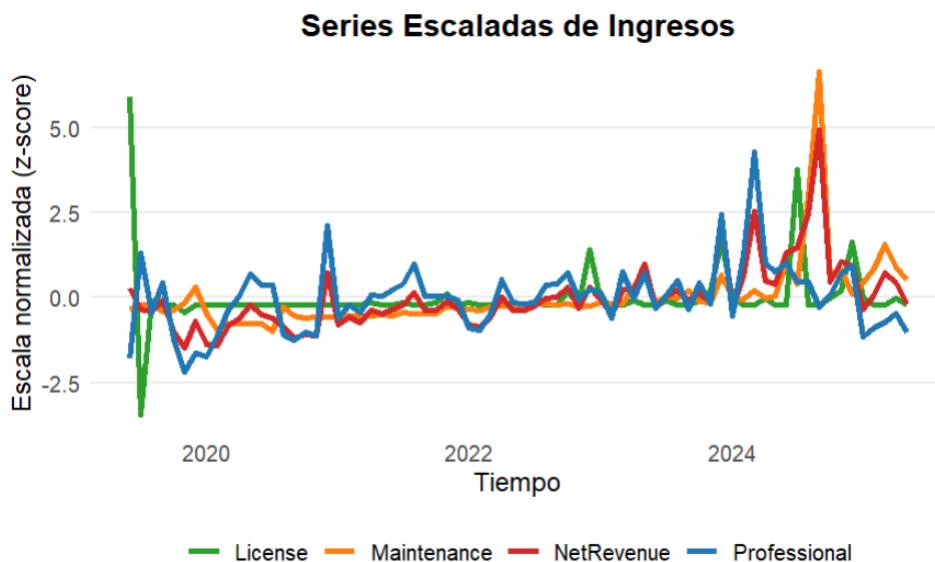


Elaboración: Propia / Software R

En la Figura 1 se observa la evolución temporal de los principales componentes de ingreso de la empresa. La variable “Professional Services” muestra una variabilidad significativa, con picos recurrentes a lo largo del tiempo y una leve tendencia decreciente hacia 2025. Por su parte, “Maintenance and Warranty” presenta un crecimiento sostenido con un fuerte incremento puntual alrededor del año 2024, asociado a contratos extraordinarios y renovaciones.

En contraste, “Licensing Revenue” mantiene un comportamiento más estable y de menor magnitud, con leves incrementos en momentos específicos, aunque con alta volatilidad relativa al inicio de la serie. Finalmente, el “Ingreso Neto”, que integra los ingresos y resta los costos directos, refleja un comportamiento cíclico con una tendencia general al alza hasta 2024, seguida de una ligera caída. Esta dinámica sugiere que el resultado neto está fuertemente influenciado por los ingresos por mantenimiento y de servicios profesionales.

Gráfico 2: Evolución histórica de las variables de ingresos sobrepuesta



Elaboración: Propia / Software R

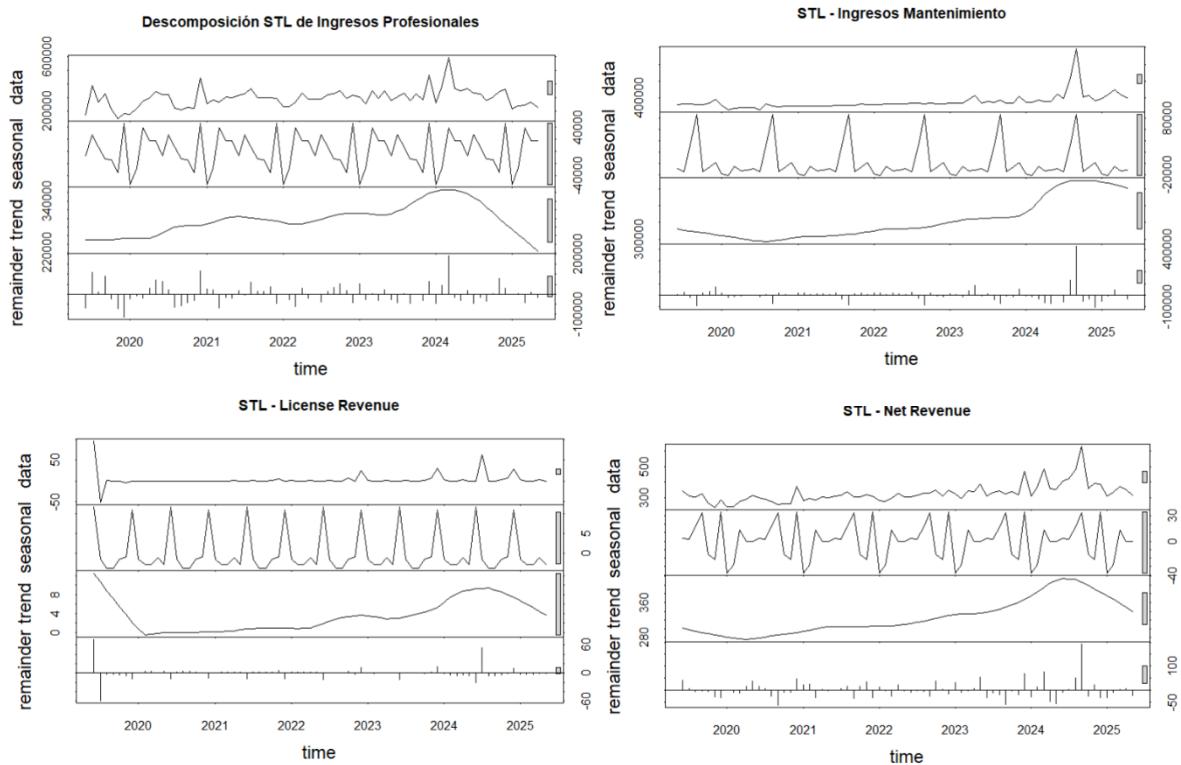
Con el objetivo de realizar una evaluación visual preliminar de la posible correlación entre las distintas fuentes de ingreso y el ingreso neto, la Figura 2 ofrece una representación clara de cómo estas variables tienden a moverse en una trayectoria similar a lo largo del tiempo. Esta relación es especialmente evidente entre los ingresos por “Professional Services” y “Maintenance”, lo que sugiere una alta dependencia conjunta en la generación del resultado neto.

Si bien la evaluación visual de las variables brinda una primera aproximación a su evolución en el tiempo, resulta limitada en términos de análisis cuantitativo. Por ello, la descomposición de series de tiempo mediante el método STL (*Seasonal-Trend decomposition using Loess*) se convierte en una herramienta clave para el análisis temporal.

Esta técnica permite descomponer la serie en tres componentes fundamentales: tendencia, estacionalidad y residuo. En este estudio, utilizando funciones base de R, se aplicó dicha descomposición a la serie de ingresos, obteniéndose cuatro representaciones: la evolución histórica, la estacionalidad, la tendencia de largo plazo y, finalmente, el componente

de residuo, que refleja las variaciones no explicadas por los factores anteriores. Esta desagregación permite comprender mejor la dinámica interna de la serie y sustenta la construcción de modelos predictivos más precisos.

Gráfico 3: Descomposición de las variables



Elaboración: Propia / Software R

En los ingresos por Servicios Profesionales y por Mantenimiento, se observa una estacionalidad marcada y consistente, junto con una tendencia estructural que alterna entre períodos de crecimiento sostenido y caídas recientes. Estos componentes aportan información clave para el modelo VAR, ya que permiten determinar la existencia de relaciones de cointegración entre las series o la necesidad de aplicar diferenciaciones previas para garantizar su estacionariedad.

Adicionalmente, la presencia de residuos significativos en determinados períodos sugiere la ocurrencia de shocks exógenos o eventos extraordinarios que deben ser considerados

al interpretar las funciones de impulso-respuesta y la dinámica entre variables. Su análisis es fundamental para evaluar la estabilidad del sistema y la validez de las respuestas dinámicas obtenidas mediante el modelo.

Considerando la presencia de componentes estructurales como tendencia y estacionalidad, así como la aparición de residuos atípicos en ciertos períodos, se vuelve esencial verificar la estacionariedad de las series antes de avanzar en la modelación. En este contexto, la aplicación del test de Dickey-Fuller aumentado (ADF) permite evaluar si las series son estacionarias en niveles o si requieren diferenciación.

El test de Dickey-Fuller aumentado (ADF) es una herramienta fundamental para evaluar la estacionariedad de las series temporales, condición necesaria para evitar relaciones espurias en modelos como el VAR. Este test contrasta la hipótesis nula de presencia de raíz unitaria, es decir, que la serie no es estacionaria, frente a la alternativa de estacionariedad. Según Gujarati y Porter (2010), “el uso de series no estacionarias puede llevar a resultados estadísticamente significativos, pero económicamente sin sentido, debido a correlaciones espurias”.

Tabla 3. Resultado del test ADF

Variable	Estadístico ADF	Valor-p	Conclusión preliminar
IngPS	-29.369	0.1938	No estacionaria
IngMA	-35.031	0.04793	Estacionaria
LR	-46.879	0.01	Estacionaria
NR	-36.930	0.03165	Estacionaria

Elaboración: Propia

Los resultados de la prueba ADF indican que la variable Ingresos por Servicios Profesionales (IngPS) no es estacionaria, dado que su valor-p (0.1938) es superior al nivel de significancia del 5%. Esto implica que la serie presenta una raíz unitaria y, por tanto, requiere

diferenciación para ser incluida de forma válida en un modelo VAR. Su comportamiento refleja una fuerte tendencia o componente estructural que debe ser tratada para evitar relaciones espurias en el análisis multivariado.

Por otro lado, las series correspondientes a Ingresos por Mantenimiento (IngMA), Licencias (LR) e Ingreso Neto (NR) presentan valores-p inferiores al umbral del 5%, lo que permite rechazar la hipótesis nula de no estacionariedad. Cabe destacar que la identificación de series no estacionarias es crucial, ya que su inclusión sin transformación puede invalidar los supuestos del modelo VAR y conducir a inferencias erróneas. Por esta razón, es recomendable aplicar una diferenciación a la serie antes de integrarla al modelo, mientras que las demás pueden ser utilizadas en su forma original.

Dado que la serie correspondiente a los Ingresos por Servicios Profesionales (IngPS) no presentó estacionariedad en niveles, como se evidenció en la prueba ADF con un valor-p de 0.1938, se procedió a su transformación mediante una diferenciación de primer orden. Esta técnica permite eliminar tendencias persistentes, estabilizando la varianza y la media de la serie en el tiempo.

Tabla 4. Resultado de la diferenciación

Variable	Estadístico ADF	Valor-p	Conclusión Preliminar
diff_IngPS	-4,9983	0,01	Estacionaria

Elaboración: Propia

El valor-p de 0.01 y un estadístico ADF de -4.9983 confirman que la serie diferenciada es estacionaria al 1% de significancia, validando su uso en el modelo. Con este resultado, todas las variables del sistema cumplen con los requisitos de estacionariedad, paso fundamental para la aplicación del modelo VAR.

Previo a la estimación del modelo VAR, se evaluó el número óptimo de rezagos utilizando los principales criterios de información: Akaike (AIC), Hannan-Quinn (HQ), Schwarz (SC) y el Error de Predicción Final (FPE). Los resultados muestran que los criterios AIC, HQ y FPE coinciden en sugerir un rezago de 12 periodos, mientras que el criterio más conservador, SC, recomienda un rezago de 3 periodos. Dado que rezagos largos pueden implicar pérdida de grados de libertad y comprendiendo la cantidad de datos con los que se cuenta, se optó por seguir el criterio SC.

La estimación del modelo VAR con tres rezagos y cuatro variables endógenas proporciona un marco cuantitativo robusto para analizar la dinámica conjunta entre los diferentes tipos de ingresos de la empresa. El desempeño del modelo, medido por los valores de R^2 ajustado y las estadísticas F, revela una capacidad explicativa en las ecuaciones. Principalmente en los ingresos por mantenimiento y servicios profesionales frente al ingreso neto.

Se identifican relaciones dinámicas intertemporales que son especialmente relevantes para la planificación financiera. Por ejemplo, en la ecuación de *diff_IngPS*, el coeficiente significativo de *LR* rezagado tres periodos indica que los ingresos por licencias tienen un efecto positivo y retardado sobre los ingresos por servicios profesionales. Esta relación puede interpretarse como un ciclo de captación de clientes a través de licencias, que se traduce luego en servicios de consultoría o implementación.

Esta interacción tiene implicaciones directas para el área PS, ya que revela cómo ciertos ingresos “pasivos” (como licencias) pueden detonar oportunidades de ingresos “activos” en meses posteriores. Finalmente, la alta correlación entre los residuos de *diff_IngPS* y *NR* (0.80), así como entre *IngMA* y *NR* (0.73), confirma que el ingreso neto está fuertemente condicionado por las fluctuaciones en servicios profesionales y mantenimiento. Este hallazgo

valida empíricamente el criterio de centrar el análisis de eficiencia financiera en el área de PS, ya que cualquier variación en su comportamiento incide directamente sobre el resultado financiero consolidado de la empresa.

Tabla 5. Resultado del modelo VAR

Variable dependiente	Ajuste del modelo (R ² ajustado)	Precisión del modelo (Error estándar)	Significación global (F-statistic y p-valor)	Interpretación general
diff_IngPS (Servicios Profesionales)	0.39	60.1	4.58 (p = 0.00004)	Modelo explicativo. Relación significativa NR
IngMA (Mantenimiento)	0.66	57.12	11.67 (p < 0.001)	Modelo robusto. Bien explicado por rezagos propios y relaciones con otras variables.
LR (Licencias)	0.29	7.95	3.23 (p = 0.0015)	Ajuste limitado. Influencia significativa de servicios profesionales rezagados.
NR (Ingreso Neto)	0.44	47.4	5.36 (p < 0.001)	Modelo adecuado. Fuertemente condicionado por PS y mantenimiento.

Elaboración: Propia

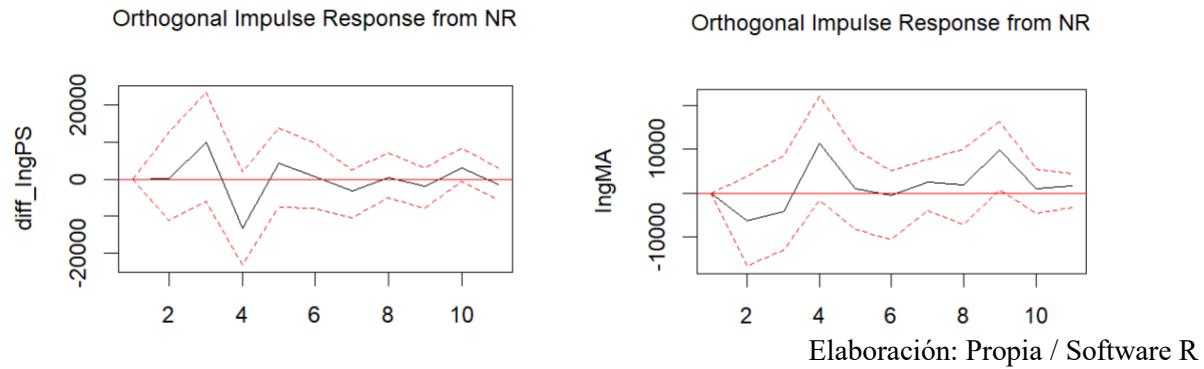
Una vez estimado el modelo VAR, el análisis de impulso-respuesta se convierte en una herramienta clave para comprender la dinámica causal entre las variables. Este enfoque permite evaluar cómo un shock exógeno en una variable A diferencia de la simple correlación estática, las funciones de impulso-respuesta capturan la magnitud, dirección y persistencia de los efectos dinámicos, lo que resulta esencial para la toma de decisiones estratégicas.

Los resultados del análisis de impulso-respuesta revelan que un shock positivo en el Ingreso Neto. En el caso de los Servicios Profesionales, la reacción es leve y transitoria, con oscilaciones que se disipan rápidamente, mientras que en los Ingresos por Mantenimiento se observa una respuesta más fuerte y persistente.

Desde una perspectiva financiera aplicada, estos hallazgos indican que una mejora en la rentabilidad global de la empresa puede y debe capitalizarse mediante estrategias que potencien líneas de ingreso recurrente. Para el área de Professional Services, esto también representa una alerta: el crecimiento del ingreso neto no garantiza mayor demanda automática de sus servicios, por lo que se requiere una estrategia más activa de conversión de valor

contable en oportunidad comercial, alineando tiempos de ejecución, capacidades operativas y comunicación comercial al comportamiento dinámico de otras unidades de ingreso.

Gráfico 4: Impulso respuesta de las variables



La prueba de causalidad de Granger permite evaluar si una variable contiene información útil para predecir otra dentro de un marco temporal. No implica causalidad en sentido estricto, sino una relación predictiva estadística, es decir, si los valores pasados de una variable ayudan a mejorar la predicción de otra. (Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. , 2015)

La prueba de causalidad de Granger revela que ambas variables anticipan significativamente el comportamiento futuro de los ingresos, lo que sugiere una dependencia estructural de PS y MA. En primer lugar, se identifica que tanto LR como IngMA presentan una causalidad estadísticamente significativa sobre diff_IngPS, lo cual indica que sus valores pasados permiten predecir con precisión la evolución de los ingresos de PS. Además, se observó una relación causal instantánea entre estas variables, lo que sugiere una sincronización temporal en sus movimientos, posiblemente relacionada con decisiones.

Desde una perspectiva financiera agregada, el área de servicios profesionales (PS) muestra una fuerte contribución a los ingresos netos de la organización. Los resultados del análisis de causalidad respaldan que PS no solo recibe influencia de otras fuentes clave de

ingreso, sino que también tiene un impacto en ellas, destacando su rol estratégico dentro del modelo de negocio.

Tabla 5. Resultado de la prueba de Granger

Causalidad estudiada	F-Test (Granger)	P value (p)	Resumen
LR -> diff_IngPS	9.159,00	9.38e-12	Si existe causalidad
IngMA -> diff_IngPS	3.689,00	0.000245	Si existe causalidad
diff_IngPs -> IngMA	37.122,00	0.00002343	Si existe causalidad

Elaboración: Propia

Gráfico 5: Forecast de los ingresos de Profesional Services

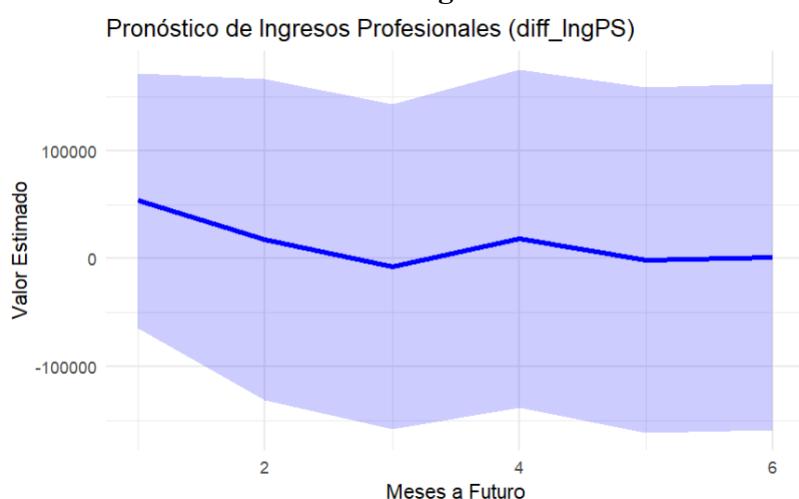
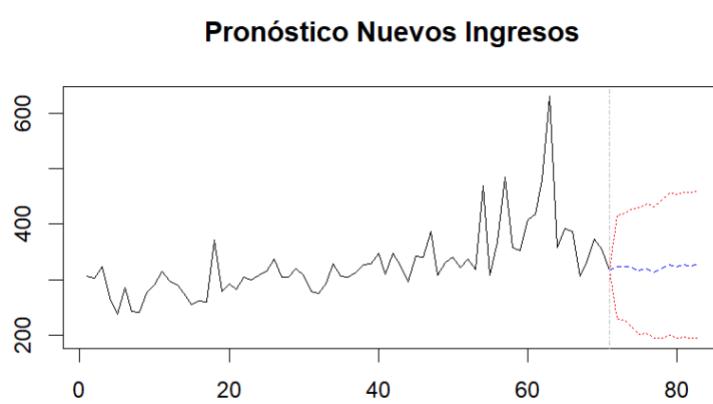


Gráfico 6: Pronóstico del Net Revenue



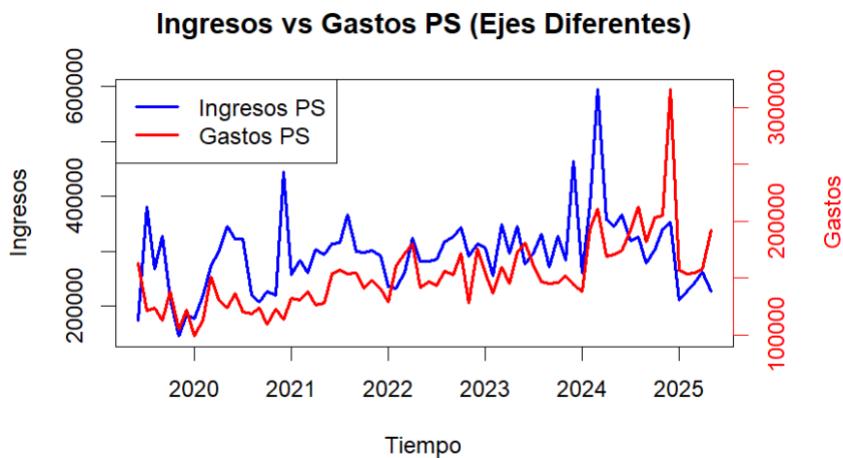
Finalmente realizando la predicción de los ingresos, en el gráfico 5 se presenta el pronóstico de la variación mensual de los ingresos de Servicios Profesionales, no el valor absoluto de los ingresos. Al tratarse de una serie diferenciada, los valores negativos no implican ingresos negativos, sino una reducción respecto al mes anterior. En este contexto, la caída proyectada durante los primeros tres meses, seguida por una estabilización, indica que los ingresos profesionales están entrando en una fase de menor crecimiento o incluso estancamiento.

Por su parte en el gráfico 6, se refleja los ingresos netos totales, se aprecia que a pesar de la estabilización de los ingresos de PS, el ingreso neto mantiene una trayectoria más estable y controlada. Esta disociación revela un fenómeno relevante: el área de PS podría estar perdiendo fuerza como impulsor primario del ingreso global o, en su defecto, otros componentes del ingreso están compensando su variación.

Este análisis confirma que, aunque los ingresos netos totales se proyectan con una relativa estabilidad, el área de Servicios Profesionales requiere especial atención. Su comportamiento volátil, evidenciado en la serie diferenciada, implica que pequeñas variaciones en sus ingresos afectan la rentabilidad y el KPI de eficiencia (Ingreso/Gasto).

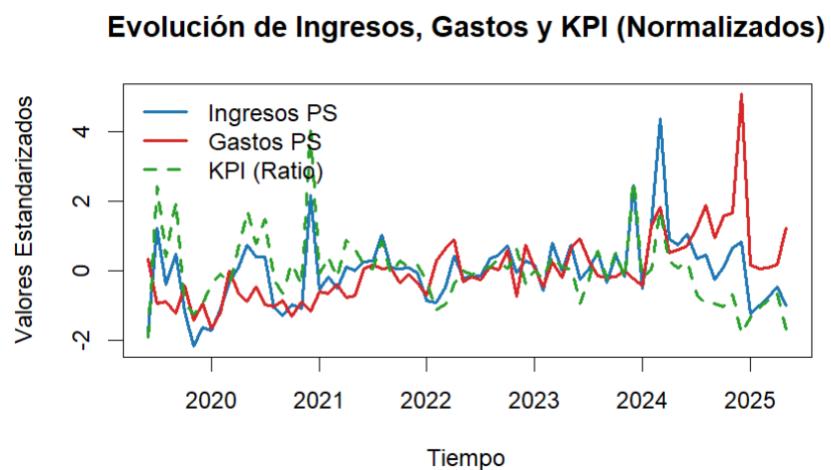
Comprendiendo la relevancia estratégica del área de Servicios Profesionales (PS), tanto por su contribución directa al ingreso total como por su influencia en otras líneas de negocio, resulta fundamental analizar cómo su comportamiento impacta el desempeño global de la compañía. En este sentido, se desarrolla un análisis detallado de la relación entre gasto e ingreso dentro del área, con el objetivo de identificar patrones, medir eficiencia y evaluar su efecto en la rentabilidad general.

Gráfico 7: Desarrollo histórico de los ingresos y gastos de área



El Gráfico 7 muestra la evolución conjunta de los ingresos y gastos del área de Servicios Profesionales (PS), representados con ejes diferenciados para facilitar la visualización de su comportamiento. A lo largo del tiempo, se observa una correlación notable entre ambas variables: cuando los ingresos aumentan, los gastos también tienden a elevarse, lo que sugiere una relación operativa estrecha entre el esfuerzo comercial y los costos asociados. Esta visualización respalda la necesidad de monitorear el KPI Ingresos/Gastos para garantizar que el área mantenga su contribución positiva al resultado operativo de la compañía.

Gráfico 8: Evolución de las variables ingreso, gasto y KPI de PS

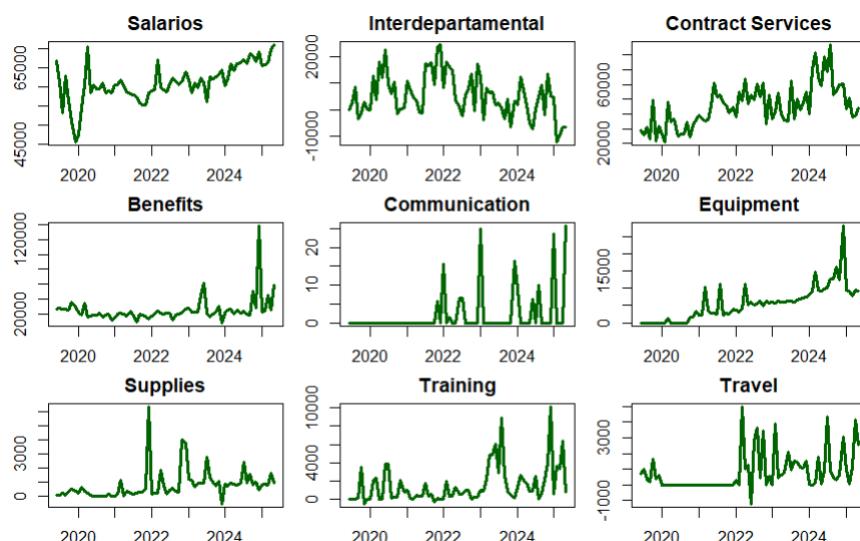


El Gráfico 8 presenta la evolución estandarizada de los ingresos, gastos y el KPI de eficiencia financiera (Ingresos PS / Gastos PS) del área de Servicios Profesionales (PS). La línea verde punteada representa dicho KPI, cuyo valor ideal debe mantenerse por encima de 2 para asegurar una rentabilidad sostenible.

A lo largo del período analizado, se observan momentos en los que el KPI se eleva significativamente, coincidiendo con un mayor crecimiento relativo de los ingresos frente a los gastos, especialmente a inicios de 2020 y durante picos en 2024. Sin embargo, también existen momentos críticos donde el KPI cae, reflejando una desproporción entre lo que se invierte y lo que se genera en retorno.

Esta relación evidencia la importancia de analizar de manera detallada qué componentes del gasto impactan de forma positiva en el ingreso. Identificar aquellos rubros que, al ser incrementados, potencian la generación de ingresos permite orientar la planificación financiera hacia una asignación estratégica de recursos. Comprender esta dinámica no solo es clave para sostener el KPI por encima del umbral deseado, sino también para mejorar la toma de decisiones presupuestarias.

Gráfico 9: Evolución de los componentes del gasto



Elaboración: Propia / Software R

El análisis de la evolución temporal de los principales componentes del gasto del área de Servicios Profesionales (PS) permite identificar patrones relevantes para la toma de decisiones estratégicas. En el gráfico se presentan las nueve variables con mayor incidencia en el gasto total, incluyendo rubros como Salarios, Interdepartamental, Contract Services y Benefits. Estas series temporales muestran variaciones significativas a lo largo del tiempo, con tendencias estacionales, picos abruptos y comportamientos crecientes o irregulares.

A partir del análisis de regresión múltiple aplicado, se buscó cuantificar el efecto de los distintos componentes del gasto sobre los ingresos del área de Servicios Profesionales (PS). Este modelo permite identificar cuáles rubros tienen un impacto significativo en la generación de ingresos. De los resultados obtenidos, se observa que la variable Contract Services presenta una relación positiva y estadísticamente significativa ($p\text{-value} = 0.0206$), indicando que un incremento en este tipo de gasto tiende a estar asociado con un aumento en los ingresos del área.

Por otro lado, variables como Salarios, Interdepartamental y Equipment también muestran coeficientes positivos, aunque con niveles de significancia más débiles. En contraste, gastos como Benefits, Supplies y Travel exhiben signos negativos, lo que podría sugerir un efecto desfavorable o menos eficiente sobre los ingresos.

Gráfico 10: Resultado del modelo.

Coefficients:					
	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	82178.2344	111023.5470	0.740	0.4620	
Salarios	2.2747	1.8151	1.253	0.2148	
Interdepartamental	1.5964	0.8972	1.779	0.0801	.
ContractServices	1.7003	0.7153	2.377	0.0206	*
Benefits	-0.9462	0.6034	-1.568	0.1219	
Communication	-1239.7569	1277.2682	-0.971	0.3355	
Equipment	3.7251	2.8250	1.319	0.1921	
Supplies	-9.8271	7.0431	-1.395	0.1679	
Training	4.0933	4.3408	0.943	0.3493	
Travel	-6.7575	6.2396	-1.083	0.2830	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1					

De igual manera se puede influir en que, por cada dólar adicional invertido en servicios contratados, los ingresos aumentan en aproximadamente \$1.70, lo que sugiere una alta eficiencia de retorno para este tipo de gasto. Mientras que, la inversión en Travel sugiere que por cada dólar adicional en viajes, los ingresos disminuyen en \$6.75, lo que indicaría un gasto ineficiente, aunque también sin significancia estadística fuerte.

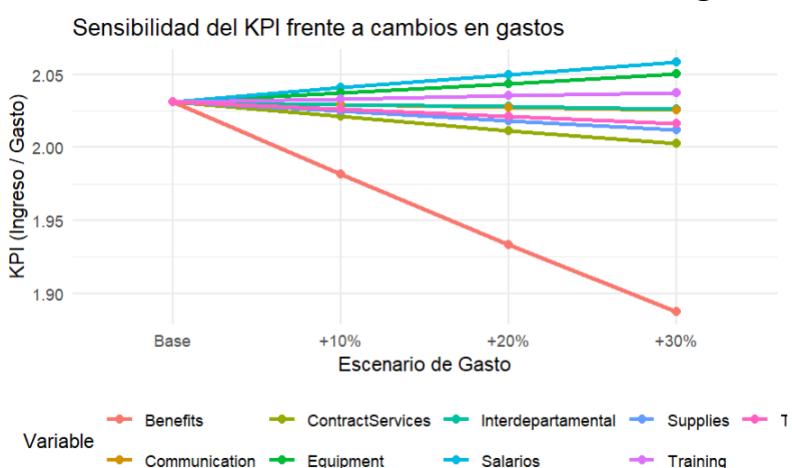
Comprendiendo la relación de los gastos frente a los ingresos y su relación, se realizó el modelo de regresión Lasso, que a diferencia de la regresión múltiple tradicional, Lasso penaliza los coeficientes de menor relevancia, reduciéndolos a cero si no aportan significativamente al modelo, lo que permite obtener un modelo más interpretativo y robusto.

Los resultados muestran que Training, Equipment, Salarios, e Interdepartamental presentan coeficientes positivos, indicando que aumentos en estos gastos están asociados a incrementos en los ingresos. Particularmente, Training (3.06) y Equipment (2.95) reflejan los mayores efectos marginales positivos, reforzando su importancia como palancas de crecimiento para el área. En cambio, variables como Travel (-5.50), Supplies (-7.45) y Communication (-984.43) muestran coeficientes negativos.

A partir de las relaciones identificadas entre ingresos y los distintos tipos de gasto, se aplicaron modelos de machine learning con el objetivo de predecir cómo los aumentos porcentuales en cada categoría de gasto afectan no solo el ingreso proyectado, sino también el comportamiento del KPI (definido como Ingreso/Gasto). El gráfico 11 se presenta un análisis de sensibilidad que evalúa el impacto relativo de aumentos del 10%, 20% y 30% en cada componente del gasto del área de Professional Services, manteniendo constantes las demás variables.

El análisis permite observar que "Benefits" tiene el impacto negativo sobre el KPI, a medida que este gasto aumenta, el KPI disminuye significativamente, lo que indica que este rubro genera un retorno relativamente bajo en ingresos. Por otro lado, variables como "Salarios", "Training" y "Equipment" tienen una pendiente positiva, mostrando que un aumento en estos gastos se traduce en una mejora del KPI, es decir, son inversiones más rentables desde la perspectiva de ingresos generados.

Gráfico 11: Sensibilidad del KPI frente al gasto



Elaboración: Propia / Software R

Este análisis es clave para la toma de decisiones presupuestarias: permite identificar qué rubros pueden ser potenciados para incrementar el retorno financiero del área, y cuáles deberían ser controlados o justificados con mayor precisión. En ese sentido, la priorización de gastos en Salarios, Capacitación y Equipamiento parece ser una estrategia más eficiente para mantener o mejorar la relación ingresos/gastos del área.

CAPITULO 4

Conclusión

El presente análisis ha permitido evidenciar con claridad la relevancia del área de Professional Services (PS) en la estructura financiera de la compañía, especialmente en su influencia directa sobre los ingresos netos. A lo largo del estudio se demostró, a través de pruebas de causalidad y modelos econométricos, que los ingresos provenientes de PS no solo aportan de forma significativa al total de ingresos, sino que también presentan una relación dinámica con otras fuentes de ingreso. Esta correlación refuerza la hipótesis de que el desempeño del área de PS puede anticipar, explicar y potenciar el comportamiento general del negocio.

Profundizando en su dinámica interna, se analizó cómo las distintas categorías de gasto dentro del área de PS afectan los ingresos generados. Mediante la aplicación de modelos de regresión múltiple y técnicas de regularización como Lasso, fue posible identificar qué rubros tienen un mayor peso positivo o negativo sobre la generación de ingresos.

Por ejemplo, partidas como “Contract Services”, “Salaries” y “Equipment” mostraron una correlación positiva con los ingresos, lo que sugiere que incrementar la inversión en estas áreas podría potenciar la rentabilidad del área. Por el contrario, gastos como “Benefits” o “Travel” demostraron una relación negativa, alertando sobre la necesidad de evaluar su eficiencia y retorno.

Esta relación fue validada también mediante el análisis del KPI específico del área (Ingresos/Gastos), el cual mostró variaciones significativas ante incrementos simulados en ciertos tipos de gasto. El análisis de sensibilidad del KPI frente a cambios en los gastos permitió visualizar cómo pequeños aumentos porcentuales en determinados rubros impactan de manera diferenciada la eficiencia financiera del área. Esta herramienta, además de facilitar la toma de

decisiones estratégicas, demuestra el valor de aplicar un enfoque cuantitativo en la gestión financiera operativa.

Un punto clave que emerge del estudio es la utilidad de las herramientas tecnológicas y los modelos matemáticos en el análisis financiero. El uso de lenguajes como R, junto con librerías especializadas y enfoques como el modelo VAR, forecast multivariado y algoritmos de machine learning, permite no solo describir la realidad financiera de la empresa, sino también anticiparla.

En este caso, se logró proyectar ingresos futuros, analizar impactos simulados y generar escenarios que ayudan en la planificación operativa y estratégica. De hecho, este estudio demuestra de forma simplificada la posibilidad de emplear herramientas de análisis de datos para fortalecer la toma de decisiones y automatizar procesos clave de planificación financiera.

La capacidad de generar modelos predictivos a partir de datos históricos no solo reduce significativamente el tiempo dedicado a tareas operativas, sino que también proporciona información valiosa que puede ser utilizada como input por gerencias y mandos medios. Esta automatización permite anticiparse a escenarios futuros, evaluar con mayor precisión el impacto de distintas decisiones financieras y estructurar estrategias más efectivas.

Finalmente, el uso de machine learning complementó de forma efectiva el análisis tradicional, permitiendo construir modelos más robustos y con capacidad de adaptarse a patrones no lineales y estructuras más complejas de los datos. La integración de estos modelos con estrategias de optimización y simulación financiera proporciona a la empresa un enfoque moderno, ágil y orientado a resultados.

Esta investigación se posiciona como un pilar fundamental para la futura implementación de técnicas de machine learning en las finanzas corporativas, promoviendo

una planificación basada en datos, modelos cuantitativos y proyecciones más precisas. Su aplicación impulsa la transición hacia una gestión financiera más inteligente, predictiva y alineada con las demandas actuales del entorno empresarial.

Recomendaciones del estudio

Una primera recomendación clave derivada de este análisis es la necesidad de ampliar y enriquecer la base de datos histórica utilizada para la modelación. Algunas categorías de gasto, como “Travel”, reflejaron comportamientos atípicos debido a eventos extraordinarios como la pandemia por COVID-19, que ocasionó una drástica reducción o incluso la suspensión de este tipo de gasto durante largos períodos. Esta discontinuidad limita la capacidad de los modelos para identificar patrones reales de comportamiento y evaluar con mayor precisión su impacto en los ingresos.

Adicionalmente, si bien el estudio aplicó modelos estadísticos clásicos como regresión múltiple y métodos de regularización como Lasso, así como análisis de causalidad y modelos VAR, se recomienda incorporar técnicas de aprendizaje automático más avanzadas en futuras investigaciones. Métodos como Random Forest, redes neuronales artificiales (ANN) o modelos de boosting (como XGBoost) pueden capturar relaciones no lineales y efectos de interacción que los modelos lineales no detectan fácilmente.

Como recomendación para futuros estudios, se sugiere ampliar la investigación a todas las áreas operativas de la empresa con el fin de obtener una visión más integral del desempeño financiero y operacional. Esta ampliación permitiría comprender con mayor precisión cómo interactúan las distintas unidades y cómo contribuyen al resultado global.

También se sugiere integrar al análisis nuevas variables externas que podrían estar influyendo en el comportamiento de los ingresos, como indicadores macroeconómicos,

variables de mercado, estacionalidad de la demanda o eventos contractuales relevantes. Estos factores externos pueden actuar como predictores significativos y ayudar a contextualizar los resultados internos.

Una recomendación estratégica clave derivada de este estudio es fomentar la implementación de políticas robustas de data governance que garanticen la calidad, trazabilidad y seguridad de los datos utilizados en la planificación financiera. Además, se sugiere evaluar cambios organizacionales que integren de manera más estructurada equipos de analítica dentro de la toma de decisiones financieras, permitiendo una cultura orientada a los datos.

Finalmente, se recomienda institucionalizar este tipo de análisis dentro de los procesos regulares de planificación financiera y evaluación de desempeño. Los modelos predictivos, combinados con simulaciones de sensibilidad, deben convertirse en herramientas estratégicas para gestionar la eficiencia operativa de las áreas. Con una correcta automatización y mantenimiento de los modelos, la organización puede no solo anticipar resultados financieros, sino también evaluar de manera proactiva diferentes escenarios de gasto e inversión.

Limitaciones del estudio

Una de las principales limitaciones del presente análisis radica en la disponibilidad y calidad de los datos históricos utilizados. Algunas series temporales presentan vacíos, discontinuidades o valores atípicos que responden a eventos no recurrentes, como la pandemia, que alteraron significativamente el comportamiento normal de ciertos gastos (como los de viaje o entrenamiento). Además, en varias categorías, los datos solo están disponibles desde años recientes, lo cual reduce la capacidad de los modelos para capturar ciclos completos o comportamientos estructurales de largo plazo. Esta restricción en el horizonte temporal afecta directamente la robustez y confiabilidad de los resultados obtenidos.

Otra limitación importante se relaciona con el enfoque de estandarización de datos y ratios aplicado en el estudio. Para fines comparativos y de interpretación relativa, se trabajó con series diferenciadas y relaciones como el KPI Ingreso/Gasto, lo cual fue útil para entender direcciones y proporciones. Sin embargo, esto implicó no trabajar directamente con montos monetarios reales en algunos tramos del análisis. Por ello, si bien se identificaron variables que influyen positiva o negativamente en el desempeño del área, no se puede aún cuantificar con exactitud el impacto económico en términos absolutos.

Si bien en el presente trabajo se enfocó en la construcción y análisis de modelos con base en datos históricos reales, no se implementaron validaciones externas con nuevos datos, por la cantidad de observaciones disponibles. Por tanto, se reconoce que la ausencia de esta etapa puede limitar la generalización de los hallazgos, por lo que su inclusión representaría un avance metodológico clave para futuras investigaciones. Es recomendable incorporar técnicas de validación cruzada, como k-fold cross-validation, en estudios futuros. Este tipo de validación permitiría evaluar la estabilidad y capacidad predictiva de los modelos desarrollados al aplicar particiones de los datos para entrenamiento y prueba de manera iterativa.

BIBLIOGRAFÍA

Alexander, J. (2018). Financial Planning & Analysis and Performance Management. Wiley.

Amaya, J. (2009). Métodos cuantitativos para la administración. Bogotá: Ecoe Ediciones .

Anthony, R. N., & Govindarajan, V. (2012). Management Control Systems. McGraw-Hill.

Bali, T. G., Cakici, N., & Whitelaw, R. F. (2011). Maxing out: Stocks as lotteries and the cross-section of expected returns. *Journal of Financial Economics*, 427-446.

Berk, J., & DeMarzo, P. (2005). Corporate Finance. Pearson Education.

Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 307-327.

Box, G., & Jenkins, G. (2016, March). Time series analysis: Forecasting and Control. Retrieved from https://www.researchgate.net/publication/299459188_Time_Series_Analysis_Forecasting_and_Control5th_Edition_by_George_E_P_Box_Gwilym_M_Jenkins_Gregory_C_Reinsel_and_Greta_M_Ljung_2015_Published_by_John_Wiley_and_Sons_Inc_Hoboken_New_Jersey_p_712_ISBN_

Brealey, R. A., Myers, S. C., & Allen, F. . (2019). Principles Of Corporate Finance. In R. A. Brealey, Principles Of Corporate Finance. McGraw-Hill Education.

Brigham, E. F., & Houston, J. F. . (2019). Fundamentals of Financial Management. Cengage Learning.

Canova, F. &. (1993). Monetary policy misspecification in VAR models. Centre for Economic Policy Research.

CFI. (n.d.). CFI. Retrieved from Rolling Forecast : <https://corporatefinanceinstitute.com/resources/accounting/rolling-forecast/>

Creswell, J. W. (2014). Research Design: Qualitative, Quantitative, and Mixed Methods Approaches. SAGE Publications.

Damodaran, A. (2012). Investment Valuation: Tools and Techniques for Determining the Value of Any Asset. Wiley.

Dayananda, D., Irons, R., Harrison, S., Herbohn, J., & Rowland, P. (2002). Capital Budgeting: Financial Appraisal of Investment Projects. ResearchGate, https://www.researchgate.net/publication/344640479_Capital_Budgeting_Financial_Appraisal_of_Investment_Projects.

De Prado, M. L. (2018). Advances in Financial Machine Learning. Wiley.

Derman, E. (2011). Models. Behaving. Badly.: Why Confusing Illusion with Reality Can Lead to Disaster, on Wall Street and in Life. In E. Derman, Models. Behaving. Badly.: Why Confusing Illusion with Reality Can Lead to Disaster, on Wall Street and in Life. Wiley.

El blog de los contadores. (2024, Septiembre 18). El blog de los contadores. Retrieved from El blog de los contadores: <https://contabilidadblog.com/estados-financieros-proforma-ejemplos-y-casos-practicos/>

El-Sayed Ebaid, I. (2009). The impact of capital-structure choice on firm performance: empirical evidence from Egypt. The Journal of Risk Finance, 477-487.

Enders, W. (2014). *Applied econometric time series*. Alabama: Wiley.

Faust, J. &. (1997). When do long-run identifying restrictions give reliable results? *Journal of Business & Economic Statistics*, 345-353.

Forbes. (2024, Jul 24). The Present And Future Of Financial Planning And Analysis (FP&A). Retrieved from Forbes: <https://www.forbes.com/councils/forbesfinancecouncil/2023/07/24/the-present-and-future-of-financial-planning-and-analysis-fpa/>

Frank J. Fabozzi, Sergio M. Focardi, Petter N. Kolm. (2012). *Financial Modeling of the Equity Market: From CAPM to Cointegration*. Wiley .

Fraser, L. M., & Ormiston, A. . (2015). *Understanding Financial Statements*. Pearson.

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. . (2015). *Multivariate Data Analysis*. Pearson Education.

Harvard Business Review. (2018). Case Study: Coca-Cola's Transformation of Financial Planning Processes.

Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación*. McGraw-Hill Education.

Hill, R. C., Griffiths, W. E., & Lim, G. C. (2018). *Principles of Econometrics*. Wiley.

Horngren, C. T., Sundem, G. L., & Elliott, J. A. (2012). *Introduction to Financial Accounting*. Pearson.

James, G. W. (2013). *An introduction to statistical learning*.

James, G. W. (2013). *An Introduction to Statistical Learning*. Springer.

Javier Salmanca, P. V. (2018). Machine learning aplicado a datos. CHILE.

Kim, S. K. (2020). The Impact of Macroeconomic Shocks on Corporate Financial Structure Using VAR Models. *Journal of Applied Economics and Finance*, 45-53.

KPMG International. (2013). Kpmg.com. Retrieved from <https://assets.kpmg.com/content/dam/kpmg/pdf/2013/12/being-the-best-v2.pdf>

Londoño, J. M. (2021). Machine learning implementado en el análisis de los. 2021.

Londoño, W. (2005). Modelos de ecuaciones múltiples: Modelo Var y Cointegración. Retrieved from Universidad EAFIT: <https://repository.eafit.edu.co/server/api/core/bitstreams/da75e9b3-9aab-428b-a221-e80db39c65ce/content>

Lütkepohl, H. (2006). New Introduction to Multiple Time Series Analysis. Springer - Verlag Berlin Heidelberg.

Mamani, Y. (2018). Business Intelligence: herramientas para la toma de decisiones en procesos de negocio. Retrieved from ResearGate: https://www.researchgate.net/publication/323993348_Business_Intelligence_herramientas_para_la_toma_de_decisiones_en_procesos_de_negocio

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

Naciones Unidas. (2015). Objetivos de Desarrollo Sostenible. Retrieved from <https://www.un.org/sustainabledevelopment/es/economic-growth/>

Porter, M. E. (1985). Competitive Advantage: Creating and Sustaining Superior Peifonnance.

- Power, M. (2008). Organized Uncertainty: Designing A World of Risk Management. ResearchGate, 10.1111/j.1467-9299.2008.00756_2.x.
- Prom Peru. (2021). Software Sector Bancario y Financiero. Boletín Tecnológico, 2-16.
- Saeed, T. (2021, Octubre). The Impact of Automation in the Accounting Industry. ResearchGate.
- Shumway, R. H. (2017). Time Series Analysis and Its Applications: With R Examples. Retrieved from Springer: <https://doi.org/10.1007/978-3-319-52452-8>
- Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 1-48. Retrieved from *Econometrica*.
- Spindler., W. &. (2022). Machine learning for financial forecasting, planning and analysis: recent developments and pitfalls. *Digital Finance*, 63-88.
- Spronk, J. (2011). Financial modelling in the new millennium. In J. Spronk, European Journal of Operation Research (pp. 229-231). <https://www.sciencedirect.com/science/article/abs/pii/S0377221700002563?via%3Dihub>. Retrieved from Financial modelling in the new millennium.
- Stephen Penman. (2015). Financial Statement Analysis and Security Valuation. McGraw-Hill Education.
- Sutton, R. S. (2018). Reinforcement Learning: An Introduction. MIT Press.
- Taleb, N. N. (2007). The Black Swan. Random House.
- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society: Series B*, 267-288.

Tsay, R. S. (2005). *Analysis of Financial Time Series*. Wiley.

Turban, E., Sharda, R., Delen, D., & King, D. (2011). *Business Intelligence: A Managerial Approach*. Pearson Education.

Wasserbacher, H., Spindler, M. (2022). Machine learning for financial forecasting, planning and analysis: recent developments and pitfalls. Retrieved from <https://doi.org/10.1007/s42521-021-00046-2>

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0).

Zhang, J. G. (2020). Credit Risk Prediction with Machine Learning: A LASSO Approach. *Journal of Risk and Financial Management*, 101.

Anexos

1. Resultados de la prueba de Dickey-Fuller

Augmented Dickey-Fuller Test

```
data: IngPS
Dickey-Fuller = -2.9369, Lag order = 4, p-value = 0.1938
alternative hypothesis: stationary
```

Augmented Dickey-Fuller Test

```
data: IngMA
Dickey-Fuller = -3.5031, Lag order = 4, p-value = 0.04793
alternative hypothesis: stationary
```

Warning in adf.test(LR) : p-value smaller than printed p-value Augmented Dickey-Fuller Test

```
data: LR
Dickey-Fuller = -4.6879, Lag order = 4, p-value = 0.01
alternative hypothesis: stationary
```

Augmented Dickey-Fuller Test

```
data: NR
Dickey-Fuller = -3.693, Lag order = 4, p-value = 0.03165
alternative hypothesis: stationary
```

2. Resultado de la prueba de Dickey-Fuller a la serie diferenciada.

Augmented Dickey-Fuller Test

```
data: diff_IngPS
Dickey-Fuller = -4.9983, Lag order = 4, p-value = 0.01
alternative hypothesis: stationary
```

3. Resultado de los rezagos

```
library(vars)
datos_VAR <- cbind(diff_IngPS, IngMA, LR, NR)
datos_VAR <- na.omit(datos_VAR)
lag_select <- VARselect(datos_VAR, lag.max = 12, type = "const")
lag_select$selection

modelo_VAR <- VAR(datos_VAR, p = 3, type = "const")
summary(modelo_VAR)
```

AIC(n)	HQ(n)	SC(n)	FPE(n)
12	12	3	12

4. Resultado de causalidad de Granger

\$Granger

Granger causality H0: LR do not Granger-cause diff_IngPS
IngMA NR

data: VAR object modelo_VAR
F-Test = 9.159, df1 = 9, df2 = 220, p-value =
0.000000000009308

\$Instant

H0: No instantaneous causality between: LR and diff_IngPS
IngMA NR

data: VAR object modelo_VAR
Chi-squared = 33.257, df = 3, p-value = 0.0000002843

\$Granger

Granger causality H0: IngMA do not Granger-cause diff_IngPS
LR NR

data: VAR object modelo_VAR
F-Test = 3.698, df1 = 9, df2 = 220, p-value = 0.000245

\$Instant

H0: No instantaneous causality between: IngMA and diff_IngPS
LR NR

data: VAR object modelo_VAR
Chi-squared = 33.945, df = 3, p-value = 0.0000002034

\$Granger

Granger causality H0: diff_IngPS do not Granger-cause IngMA

LR NR

data: VAR object modelo_VAR
F-Test = 3.7122, df1 = 9, df2 = 220, p-value = 0.0002343

\$Instant

H0: No instantaneous causality between: diff_IngPS and IngMA
LR NR

data: VAR object modelo_VAR
Chi-squared = 33.951, df = 3, p-value = 0.0000002029