

Ficha de Viabilidad del Proyecto de Investigación

Información General

Información del estudiante 1	Nombre: Leidy Viviana León Parra
	Correo institucional: lleonpar7336@universidadean.edu.co
	Programa al que pertenece: Especialización en Gerencia de Proyectos
Información del estudiante 2	Nombre: Ivan Felipe Hernandez Barrera
	Correo institucional: ihernan70891@universidadean.edu.co
	Programa al que pertenece: Especialización Machine Learning
Información del estudiante 3	Nombre: Jenifer Angelica Morales Correa
	Correo institucional: jmorales4159@universidadean.edu.co
	Programa al que pertenece: Especialización Machine Learning
Información del estudiante 4	Nombre:
	Correo institucional:
	Programa al que pertenece:
Campo de investigación:	Emprendimiento y gerencia
Grupo de investigación:	Grupo de gerencia en las grandes, mediana y pequeñas empresas
Línea de investigación:	Innovación para la sostenibilidad de las organizaciones.
Título tentativo del proyecto:	Análítica Predictiva para la Inteligencia Financiera de PYMEs en Colombia

Resumen

En Colombia, las pequeñas y medianas empresas enfrentan un elevado índice de cierre debido a debilidades en su gestión financiera, planeación estratégica y baja implementación de herramientas tecnológicas. Este proyecto busca proponer lineamientos que, a partir de la analítica predictiva y el machine learning, contribuyan a fortalecer la inteligencia financiera, optimizar el crecimiento sostenible y anticipar riesgos. La investigación se desarrolla con un enfoque cualitativo, no experimental y transversal, utilizando análisis documental y entrevistas a expertos. La información será procesada mediante análisis de contenido y codificación temática. Se definen y miden variables como analítica predictiva, gestión financiera, riesgo, sostenibilidad y adopción tecnológica, lo que permitirá estructurar un marco estratégico aplicable a la realidad de las PYMEs colombianas.

Palabras clave: PYMEs, analítica predictiva, inteligencia financiera, machine learning, gestión del riesgo, adopción tecnológica.

Planteamiento del Problema

De acuerdo con el Registro Único Empresarial y Social (RUES) de Confecámaras, entre enero y junio de 2025, las pequeñas y medianas empresas en Colombia representaron el 5.2 % de las unidades productivas del país (Ministerio de Comercio, Industria y Turismo, 2025), sin embargo, según el índice de supervivencia de Confecámaras, se evidencia que el 66.5% de la empresas creadas en el 2017 cerraron sus operaciones, lo que implica que únicamente el 33.5% logró mantenerse activa después de 5 años (Confecámaras, 2023), siendo las principales causas el desconocimiento del mercado objetivo, la baja rentabilidad, la dificultad de acceso a financiamiento, **la falta de planificación empresarial** en donde se evidencia la carencia de proyecciones financieras, planes de crecimiento o contingencia y los **problemas de gestión administrativa**, tales como las deficiencias en control del inventario o flujos de caja (Confecámaras, 2023). Esta situación plantea la necesidad de implementar herramientas de analítica avanzada aplicados datos financieros y operativos de las pymes, que permitan anticipar problemas de liquidez, optimizar la gestión administrativa y fortalecer la planificación estratégica empresarial.

Antecedentes del Problema

Las pequeñas y medianas empresas (PYMEs) representan más del 90 % del tejido empresarial en América Latina y generan una parte significativa del empleo formal, consolidándose como un pilar esencial para el desarrollo económico de la región. Sin embargo, su sostenibilidad y competitividad se ven afectadas por limitaciones estructurales relacionadas

con la gestión financiera y la adopción de tecnologías de análisis avanzado, lo que restringe su capacidad de anticipar riesgos y planificar con base en datos objetivos (Ahmad & Lucas, 2024).

La aplicación de machine learning (ML) y analítica predictiva en PYMEs ha demostrado mejorar la precisión en la proyección de ventas, la predicción de flujos de caja y la optimización de inventarios, permitiendo anticipar problemas de liquidez y tomar decisiones más estratégicas (Gaertner et al., 2024). Estudios han mostrado que la integración de modelos de forecasting de series temporales, como ARIMA o Holt-Winters, en procesos de planeación financiera permite aumentar la precisión de los pronósticos en comparación con métodos tradicionales (Wasserbacher & Spindler, 2021). Estas técnicas pueden complementarse con herramientas de análisis en tiempo real, como lo son dashboards o reportes, que faciliten el seguimiento a indicadores críticos para la toma de decisiones oportunas.

Asimismo, el uso de ML para evaluar el riesgo financiero ha sido aplicado con éxito en pequeñas empresas, permitiendo identificar patrones asociados a incumplimientos de pago y prever situaciones de riesgo con suficiente antelación para implementar medidas preventivas

(Cheraghali & Molnár, 2024). Estas prácticas son especialmente relevantes en entornos emergentes, donde la volatilidad económica y la falta de acceso a capital incrementan la vulnerabilidad financiera de las PYMEs.

En el contexto colombiano, aunque existen experiencias positivas en el uso de analítica de datos para mejorar la gestión empresarial, según un estudio de EAFIT basado en la Encuesta Pulso Empresarial del DANE, 2022, tan solo el 3,1 % de empresas colombianas aplican machine

learning para análisis de datos (Otálvaro, 2023); es decir, el uso estratégico es aún muy bajo debido a barreras como el desconocimiento técnico, la percepción de altos costos y la falta de estrategias de implementación. Esta brecha entre el potencial de las herramientas de analítica y su limitada adopción en el país plantea la oportunidad para demostrar que, a partir de metodologías ya disponibles, es posible fortalecer la inteligencia financiera de las PYMEs y potenciar su crecimiento sostenible (Ahmad & Lucas, 2024).

Descripción del Problema.

Las PYMEs cuentan con datos históricos valiosos, ventas mensuales, flujos de caja, gastos operativos, inventarios, comportamiento de clientes que podrían ser la base para implementar sistemas de inteligencia financiera. Sin embargo, en la mayoría de los casos, estos datos no son procesados ni utilizados de forma estratégica para predecir escenarios futuros. Esto provoca que las decisiones se tomen de forma reactiva, basadas en la experiencia o la intuición, en lugar de en análisis objetivos (Gaertner et al., 2024)

Según el Deloitte Global Corporate Treasury Survey, el 42 % de los responsables de tesorería corporativa calificó como inexactos sus pronósticos de flujo de caja a tres a seis meses, señalando que la mala calidad de los datos (60 %) y la falta de herramientas eficaces (50 %) fueron los principales obstáculos para alcanzar previsiones confiables. En respuesta a estos desafíos, la encuesta identifica que la adopción de tecnologías como la visualización de datos, ayudan a la generación de mejores mediante el modelado de patrones de datos. (Deloitte, Noviembre 2022).

Ahora bien, la falta de modelos predictivos integrados a la gestión empresarial limita la capacidad de las PYMEs para anticipar cambios en la demanda, prever problemas de liquidez, planificar expansiones o ajustar la producción. En consecuencia, se desperdicia el potencial de herramientas como ML y analítica predictiva, que podrían integrarse mediante soluciones ya existentes sin requerir desarrollos complejos (Wasserbacher & Spindler, 2021).

La oportunidad de mejora radica en adaptar técnicas de machine learning y gestión de proyectos para que las PYMEs puedan pronosticar métricas clave y recibir recomendaciones estratégicas basadas en sus datos históricos. Esto permitiría optimizar la planeación financiera, reducir tiempos, reducir riesgos y mejorar la competitividad de manera sostenible (Ahmad & Lucas, 2024).

Pregunta de Investigación.

¿Cómo puede la aplicación de técnicas de analítica predictiva y machine learning sobre datos financieros y operativos fortalecer la inteligencia financiera de PYMEs en Colombia para optimizar su crecimiento sostenible y gestión del riesgo?

Objetivos

Objetivo General.

Proponer un marco de lineamientos estratégicos, basado en técnicas de analítica predictiva y machine learning, para fortalecer la inteligencia financiera, optimizar el crecimiento sostenible y gestionar el riesgo en las PYMEs de Colombia.

Objetivos Específicos.

- Identificar las principales limitaciones que enfrentan las PYMEs colombianas en la gestión de datos financieros y la toma de decisiones estratégicas, analizando factores como el desconocimiento técnico, la falta de acceso a herramientas tecnológicas y la baja adopción de modelos analíticos.
- Explorar las técnicas de analítica predictiva y machine learning más utilizadas para la proyección de ventas, flujos de caja y análisis de riesgo financiero, evaluando su aplicabilidad y efectividad en el contexto de las PYMEs.
- Evaluar los beneficios y desafíos de implementar modelos predictivos en machine learning, como ARIMA y Holt-Winters, en la planeación financiera de las PYMEs, comparando su desempeño frente a métodos tradicionales de pronóstico.
- Analizar casos de uso o experiencias exitosas en la adopción de soluciones basadas en machine learning y dashboards en pequeñas y medianas empresas en Colombia, con el fin de exponer lecciones y mejoras sustanciales que puedan ser aplicadas en las PYMES.
- Proponer lineamientos estratégicos para la adopción de herramientas de analítica predictiva, lenguaje natural y automatización de informes financieros, que fortalezcan la inteligencia financiera y competitividad de las PYMEs en Colombia, considerando factores como el costo, la facilidad de implementación y la capacitación del personal.

Conveniencia de la Investigación

Esta investigación ofrece beneficios clave para las pequeñas y medianas empresas (PYMEs), particularmente en gestión financiera y competitividad. La implementación de modelos predictivos y machine learning (ML) permitirá a las PYMEs tomar decisiones más informadas, anticipar riesgos financieros y optimizar recursos, lo que resultará en una mejora en la sostenibilidad y crecimiento a largo plazo. Además, al ser una solución de bajo costo y fácil implementación, democratizará el acceso a tecnologías avanzadas que, aunque ya probadas en grandes empresas, aún son poco adoptadas en el contexto de las PYMEs colombianas (Herrera & Casanova, 2024)

Desde el punto de vista metodológico, este proyecto contribuirá al desarrollo de marcos aplicables para integrar analítica predictiva y machine learning en pequeñas empresas, proporcionando un modelo replicable en diversos contextos (Mendoza et al., 2025). Teóricamente, amplía el conocimiento sobre la gestión de riesgos y el uso de tecnologías emergentes en empresas de menor escala, lo que fortalecerá su competitividad y capacidad de adaptación en un entorno económico cada vez más incierto.

Marco Teórico

Estado del Arte

Las pequeñas y medianas empresas (PYMEs) en Colombia representan un pilar fundamental de la economía nacional: constituyen entre el 99 % de las empresas registradas, generan alrededor del 80 % del empleo formal y aportan aproximadamente el 35 % del Producto

Interno Bruto. (Fonseca et al., 2024). Sin embargo, su supervivencia es precaria: se estima que el 60 % de las empresas recientemente constituidas quebrarán antes de cumplir cinco años, siendo las microempresas las más afectadas. (Palomino et al., 2024).

Gran parte de esta vulnerabilidad se explica por dificultades en el manejo financiero: falta de control del flujo de caja, desconocimiento de indicadores contables y financieros, y escasa implementación de sistemas de gestión contable integrados. (Tobón et al., 2022). De hecho, en Boyacá, el 44 % de las PYMEs no cuenta con un sistema integrado de información contable, y solo una fracción elabora estados financieros comparativos completos. (Tobón et al., 2022).

En respuesta a estos desafíos, un primer grupo de investigaciones ha explorado la aplicación de la analítica predictiva como herramienta para apoyar la supervivencia y resiliencia financiera de estas empresas. Por ejemplo, se ha propuesto un modelo de analítica predictiva del flujo de caja para MiPYMEs en Colombia, con el objetivo de anticipar condiciones de insolvencia y contribuir a la sostenibilidad financiera mediante alertas tempranas. De manera complementaria, un estudio reciente se dedicó a predecir la quiebra empresarial en PYMEs colombianas utilizando técnicas de machine learning, destacando la relevancia de estos modelos para anticipar escenarios de riesgo financiero (Correa, 2023). Además, se ha evaluado la precisión del modelo Altman Z-score en empresas colombianas en proceso de reorganización, aunque sus resultados muestran una capacidad predictiva limitada (aproximadamente 33 %) en este entorno (Isaac et al., 2023).

Otros estudios, aunque no centrados exclusivamente en analítica predictiva, han investigado la adopción de tecnologías y transformación digital en las PYMEs como factores

clave para la competitividad y sostenibilidad. En el caso de Boyacá, la transformación digital se asocia con mejora en la competitividad, aunque las empresas enfrentan barreras como la infraestructura tecnológica limitada y deficientes capacidades de gestión de TIC (Fonseca et al., 2024). Asimismo, entre 2010 y 2014, la conectividad a Internet en las MiPYMEs colombianas aumentó del 7 % al 60 %, lo cual mejoró su potencial para adoptar herramientas digitales, si bien persisten obstáculos relacionados con la formación y confianza en nuevas tecnologías (Palomino et al., 2024).

En el contexto organizacional, las PYMEs en Colombia no solo está determinado por la normatividad legal y los actores de apoyo financiero, sino también por la forma en que estas organizaciones gestionan sus datos, estructuras tecnológicas y cultura organizacional. Estos tres actores son considerados pilares fundamentales para que una empresa pueda transitar de ser solamente productora de datos a convertirse en una organización data-driven (Ali, 2024), capaz de tomar decisiones informadas en lugar de la intuición, anticipándose a los riesgos mediante herramientas de analítica avanzada.

En primer lugar, el componente humano es esencial. La cultura organizacional y la disposición al cambio determinan en gran medida la adopción de soluciones analíticas. El personal administrativo y financiero debe contar con formación básica en manejo de datos y comprensión de indicadores financieros, al tiempo que se requiere la participación de perfiles especializados que lideren la implementación de modelos predictivos (Ali, 2024). En segundo lugar, el componente de datos bajo un panorama de Gobernanza establece la base para cualquier desarrollo de ML, siendo la calidad, integridad y estandarización de la información financiera y

operativa bases sólidas para construir modelos predictivos (Ali, 2024), como lo es la implementación de sistemas contables que generen estados financieros bajo la normatividad NIIF para PYMEs, la obligatoriedad de la facturación y nómina electrónicas, así como la clasificación sectorial mediante códigos CIU, permiten estructurar un flujo de información confiable.

En tercer lugar, el componente tecnológico constituye el habilitador clave para escalar soluciones de analítica predictiva. La infraestructura tecnológica puede estar basada en servidores locales, soluciones en la nube o modelos híbridos, siempre que garantice escalabilidad, seguridad y eficiencia en el procesamiento de grandes volúmenes de información.

Herramientas como Python o Pandas ofrecen alternativas accesibles para modelar y entrenar algoritmos, mientras que servicios en la nube como AWS permiten integrar de forma ágil modelos analíticos en la operación empresarial. Este ecosistema tecnológico asegura que los modelos no se queden en un nivel experimental, sino que se incorporen efectivamente en la gestión estratégica mediante tableros dinámicos y sistemas de apoyo a la decisión (Ali, 2024).

En síntesis, este estado del arte evidencia, la importancia estructural de las PYMEs en Colombia y sus desafíos financieros, los primeros avances en analítica predictiva aplicada a la gestión financiera y el contexto de transformación digital en el que estas estrategias pueden consolidarse para fortalecer la resiliencia empresarial.

Panorama Conceptual: Definiciones y Conceptos Clave

Analítica Descriptiva

La analítica descriptiva nos ayuda a entender el panorama de la empresa, comunicándonos hechos pasados y presentes, ayudándonos a entender patrones comportamientos e identificar patrones (Evans, 2019).

Analítica Predictiva

La analítica predictiva se define como un conjunto de técnicas analíticas que emplean datos históricos combinados con modelos de predicción, minería y aprendizaje automático para anticipar eventos futuros o valores faltantes mediante el análisis de patrones existentes (Liu et al., 2023). De forma complementaria, destacan que esta práctica se enmarca en el análisis de datos empresariales y busca transformar información pasada en decisiones informadas, concentrándose especialmente en métodos estadísticos y técnicas de machine (Liu et al., 2023).

Analítica Prescriptiva

La analítica prescriptiva sugiere acciones concretas para optimizar los resultados, dadas las metas y restricciones, apoyándose en modelos de optimización y simulación (Evans, 2019).

Inteligencia Financiera en el Contexto Empresarial

La inteligencia financiera puede concebirse como la capacidad que tienen las organizaciones para procesar información financiera, transformarla en indicadores significativos

y utilizarla para tomar decisiones informadas que mejoren su desempeño económico. En este sentido, la inteligencia de negocios (Business Intelligence, BI) es un soporte clave, ya que facilita la interpretación de grandes volúmenes de datos financieros para impulsar decisiones estratégicas (Valarezo et al., 2021).

Business Intelligence (BI) y su relación con la Inteligencia Financiera

Business Intelligence (BI) se define como el conjunto de tecnologías, aplicaciones y procesos para la recolección, almacenamiento, acceso y análisis de datos empresariales, orientados a apoyar la toma de decisiones estratégicas (Al-khateeb, 2024). Esta definición se refuerza en la literatura académica que señala cómo BI convierte datos en conocimiento útil para la gestión (Al-khateeb, 2024).

Transformación Digital y Competencias Organizacionales en PYMEs

Un estudio reciente basado en revisión bibliográfica en Scopus y WOS describe un modelo de competencia organizacional para la transformación digital en PYMEs. Se concluye que el aprendizaje organizacional y el conocimiento colectivo son fundamentales para que las empresas avancen en su madurez digital, lo cual es clave para implementar herramientas como la analítica predictiva. (González et al., 2024)

Modelos, Teorías y Marcos Conceptuales

Modelo Altman Z-score y Predicción de Fallo Financiero

El Modelo Altman Z-score es una herramienta clásica para anticipar la probabilidad de quiebra de una empresa. Aunque no siempre es específico a PYMEs, su simplicidad y enfoque en ratios financieros lo hacen útil en contextos con recursos limitados. Estudios recientes muestran que, si bien su precisión es menor frente a modelos de aprendizaje automático (ML), su interpretabilidad, bajo costo y baja necesidad tecnológica favorecen su adopción en empresas pequeñas (Braunsberger & Aschauer, 2025).

Modelos de Adopción Tecnológica: TAM, DOI, TOE

a) Technology Acceptance Model (TAM)

El TAM (Davis, 1989) postula que la intención de uso de una tecnología está determinada por la utilidad percibida (PU) y la facilidad de uso percibida (PEOU). Este modelo es fundamental al entender cómo los usuarios deciden adoptar tecnologías como analítica predictiva o BI (Utama et al., 2022).

b) Diffusion of Innovation (DOI) – Rogers (1995)

La Teoría de la Difusión de Innovaciones destaca cinco atributos clave que influyen en la adopción tecnológica: ventaja relativa, compatibilidad, complejidad, observabilidad y experimentación (trialability). En estudios sobre PYMEs en Colombia, se observa que los

factores más influyentes son la ventaja relativa, la observabilidad y la complejidad Intangible Capital (Osorio et al., 2016).

c) Technology–Organization–Environment (TOE)

El marco TOE, creado por Tornatzky y Fleischer (1990), establece que la adopción tecnológica depende del contexto tecnológico, organizacional y ambiental. Por ejemplo, en procesos de adopción de analítica o BI, la infraestructura de datos (tecnología), el liderazgo y los recursos internos (organización), y la presión regulatoria o mercado (entorno) son fundamentales (Nam et al., 2019).

Integración de TAM, TOE y Altman Z-score para Analítica Predictiva Financiera

Un enfoque innovador mezcla el modelo financiero (Altman Z-score) con marcos de adopción técnica (TAM y TOE) (Tay & Shen, 2023). Esta integración permite evaluar no solo la capacidad técnica de un modelo, sino también su adoptabilidad organizacional y funcionalidad estratégica. Se ha mostrado que, mientras los modelos de Z-score son más interpretables y accesibles, los modelos basados en ML tienen mejor precisión, aunque requieren mayor infraestructura y aceptación (utilidad, facilidad de uso, condiciones facilitadoras) (Braunsberger & Aschauer, 2025).

Tabla 1.

Modelos financieros y de adopción tecnológica: aportes principales.

Teoría / Modelo	Aporte Principal
Altman Z-score	Modelo financiero clásico, interpretable y de bajo costo
TAM	Explica adopción tecnológica desde percepción del usuario (PU, PEOU)

DOI	Destaca atributos de innovación que impactan adopción (ventaja, compatibilidad...)
TOE	Marco organizacional e institucional para entender adopción tecnológica
Integración (Z-score + TAM/TOE)	Permite evaluar modelos predictivos desde una perspectiva financiera y práctica

Nota: la tabla presenta los principales modelos financieros y tecnologías que orientan este estudio.

Marco Legal y Normativo

Normatividad sobre PYMEs en Colombia

Las pequeñas y medianas empresas (PYMEs) juegan un papel crucial en la economía colombiana, representando más del 90% de las unidades productivas del país (Ministerio de Comercio, Industria y Turismo, 2025). A pesar de su importancia, estas empresas enfrentan diversos desafíos, especialmente en lo que respecta a la gestión financiera y la adopción de nuevas tecnologías. En este contexto, las políticas públicas y el marco normativo que regula las PYMEs en Colombia juegan un papel central. La Ley 905 de 2004, modificada por la Ley 590 de 2000, establece directrices para mejorar la competitividad de las PYMEs mediante medidas como el acceso a financiamiento y la capacitación empresarial (Gallego, 2005). Estas leyes buscan proporcionar un marco favorable para la modernización y el desarrollo económico del sector empresarial.

La Ley 2069 de 2020, conocida como la Ley de Emprendimiento, es otro hito importante en la regulación de las PYMEs en Colombia. Esta normativa tiene como objetivo fomentar la creación de empresas emergentes, así como incentivar la adopción de tecnologías avanzadas en

el ámbito empresarial. La ley promueve la transformación digital y el uso de herramientas tecnológicas, como la analítica predictiva, para potenciar la sostenibilidad e innovación de las PYMEs (Hernández, 2021). Esta legislación es clave, ya que establece un marco regulatorio que apoya a las PYMEs no solo en su crecimiento económico, sino también en su adaptación a las nuevas exigencias del mercado global.

Normas Contables y Protección de Datos en el Contexto de las PYMEs

En términos contables, las Normas Internacionales de Información Financiera (NIIF) son esenciales para la transparencia y la calidad de la información financiera de las PYMEs. En Colombia, estas normas fueron adoptadas por la Ley 1314 de 2009, y para las pequeñas y medianas empresas se implementó una versión simplificada, las NIIF para PYMEs. Esta normativa es fundamental para garantizar la integridad y comparabilidad de los estados financieros, lo cual facilita la implementación de proyectos de analítica predictiva en la gestión financiera de las empresas (Pérez, 2012). Las PYMEs, al alinearse con estas normas, logran una mayor credibilidad en sus operaciones y mejor acceso a fuentes de financiamiento.

En cuanto al tratamiento de datos personales, la Ley 1581 de 2012 es una pieza clave de la regulación en Colombia. Esta ley establece directrices para la protección de datos personales, lo que es crucial cuando las empresas manejan información sensible, como la financiera. La implementación de herramientas de analítica predictiva requiere la recolección y el análisis de grandes volúmenes de datos, lo que hace que el cumplimiento de las normativas de protección de datos sea una prioridad (González, 2013). La seguridad y la privacidad de los datos deben

garantizarse para que las PYMEs puedan operar dentro de un marco de confianza y cumplir con las leyes de protección de la información.

A pesar de los avances regulatorios, la adopción de tecnologías avanzadas, como la analítica predictiva, enfrenta importantes barreras en las PYMEs colombianas. En primer lugar, muchas de estas empresas carecen de la infraestructura tecnológica necesaria para implementar soluciones de analítica avanzada. La falta de personal capacitado en áreas como ciencia de datos y programación también limita la capacidad de las empresas para aprovechar estas herramientas (Rodríguez, 2018). Además, la resistencia cultural frente a la digitalización es una de las barreras más difíciles de superar. Muchos empresarios aún perciben las nuevas tecnologías como inversiones costosas y difíciles de implementar en su realidad cotidiana.

Sin embargo, a pesar de estas dificultades, las oportunidades que ofrece la analítica predictiva para las PYMEs son significativas. La capacidad de anticipar riesgos financieros, mejorar la gestión de flujos de caja y optimizar la toma de decisiones estratégicas son solo algunos de los beneficios que la analítica avanzada puede aportar (Brown, 2019). Por ejemplo, las herramientas de machine learning pueden identificar patrones ocultos en los datos financieros que pueden predecir futuros problemas de liquidez o insolvencia, lo que permitiría a las empresas tomar decisiones informadas para evitar quiebras o crisis económicas (Settlements B. f., 2020). Esto abre la puerta a un nivel de previsión financiera que antes solo estaba al alcance de grandes corporaciones.

Sin embargo, como mencionan varios autores, la falta de capacitación y formación en el uso de tecnologías avanzadas sigue siendo uno de los mayores obstáculos para la adopción de la

analítica predictiva en las PYMEs. Para superar esta barrera, es necesario un enfoque integral que no solo considere la implementación de la tecnología, sino también la capacitación de los empleados y la adaptación cultural de las organizaciones (Vargas, 2017). Programas de formación en ciencia de datos y analítica predictiva son esenciales para que las PYMEs puedan aprovechar al máximo el potencial de estas herramientas y, al mismo tiempo, garantizar la sostenibilidad a largo plazo.

En cuanto a la integración de la tecnología en las PYMEs, los estudios de adopción tecnológica, como el modelo TAM (Technology Acceptance Model), explican que la aceptación de herramientas de analítica depende no solo de su utilidad percibida, sino también de la facilidad de uso y la infraestructura tecnológica disponible en las empresas (Tay & Shen, 2023).

Además, las teorías de difusión de innovaciones (DOI) y el modelo TOE (Technology, Organization, Environment) destacan que el entorno organizacional y las políticas gubernamentales son factores claves para la adopción exitosa de nuevas tecnologías. En este sentido, la legislación colombiana, como la Ley 2069 de 2020, juega un papel fundamental al proporcionar incentivos y marcos de apoyo para las empresas que deseen emprender la transición digital.

Normatividad sobre PYMEs en Colombia

En Colombia, el marco legal que regula a las pequeñas y medianas empresas se encuentra principalmente en la Ley 905 de 2004, que modifica la Ley 590 de 2000 y establece políticas para fomentar su desarrollo y competitividad. Esta ley reconoce la importancia de las PYMEs en

la economía y contempla medidas para facilitar el acceso al financiamiento, mejorar la capacitación y promover la adopción de tecnologías (Función Pública, 2025).

De manera complementaria, la Ley 2069 de 2020 o Ley de Emprendimiento introdujo incentivos para el fortalecimiento de las empresas emergentes, promoviendo la transformación digital y el acceso a instrumentos tecnológicos que apoyen la sostenibilidad y la innovación (Ministerio de Comercio, Industria y Turismo, 2025).

Para efectos de clasificación económica, las empresas deben asignar un código CIIU (Clasificación Industrial Internacional Uniforme) que es indispensable en la formalización de las empresas, clasificación sectorial y la definición de obligaciones tributarias.

Estas disposiciones reflejan un esfuerzo estatal por crear un entorno regulatorio que favorezca la modernización de las PYMEs, lo que incluye la adopción de soluciones como la analítica predictiva para la gestión financiera.

Normas Internacionales de Información Financiera (NIIF para PYMEs)

En el ámbito contable, Colombia adoptó las Normas Internacionales de Información Financiera (NIIF) a través de la Ley 1314 de 2009, con el objetivo de armonizar la información financiera con estándares internacionales. Para las PYMEs se aplica una versión simplificada de estas normas, conocida como NIIF para PYMEs, que busca asegurar la transparencia, comparabilidad y calidad de los estados financieros (IFRS, 2025)

La aplicación de NIIF para PYMEs es fundamental para proyectos de inteligencia financiera, ya que provee la base estructurada de los datos contables que posteriormente pueden ser analizados mediante técnicas de machine learning y analítica predictiva.

Regulación sobre Transformación Digital y Datos

El Documento CONPES 3920 de 2018 establece la política nacional para la transformación digital e inteligencia artificial en Colombia, fomentando el uso de tecnologías avanzadas en las empresas para mejorar su competitividad. Además, el CONPES 4011 de 2020 define lineamientos para el uso estratégico de Big Data en el país (Congreso de la República de Colombia, 2012).

En cuanto al tratamiento de datos, la Ley 1581 de 2012 regula la protección de datos personales, un aspecto clave en proyectos de analítica que manejan información financiera sensible (Congreso de la República de Colombia, 2012).

Marcos Internacionales de Referencia en Riesgo Financiero

A nivel internacional, la gestión de riesgo financiero está influenciada por los acuerdos de Basilea II y III, los cuales, aunque diseñados para entidades financieras, proveen lineamientos sobre evaluación del riesgo crediticio, de mercado y operacional que pueden adaptarse a la gestión financiera de PYMEs en contextos de analítica predictiva (Settlements B. f., 2025).

Estos marcos sirven como referentes para construir indicadores de riesgo adaptados a las realidades de empresas de menor escala.

El marco legal y normativo que regula a las PYMEs en Colombia ofrece un escenario favorable para la implementación de la analítica predictiva en la gestión financiera. Desde la Ley 905 de 2004 y la Ley 2069 de 2020 hasta la adopción de NIIF para PYMEs, el país cuenta con instrumentos que promueven la competitividad, la transparencia y la transformación digital. Sumado a esto, las políticas de CONPES y la legislación en protección de datos proporcionan garantías esenciales para el uso responsable de la información. Finalmente, los estándares internacionales como Basilea II y III constituyen marcos de referencia que pueden guiar la evaluación del riesgo financiero en pequeñas y medianas empresas.

Síntesis Crítica del Marco Teórico

La revisión del marco teórico evidencia que las PYMEs en Colombia, aunque constituyen el núcleo del tejido empresarial, enfrentan altas tasas de mortalidad y dificultades estructurales en la gestión financiera. El estado del arte muestra que la analítica predictiva y el machine learning han comenzado a explorarse como mecanismos para anticipar riesgos de liquidez, mejorar la planeación de flujos de caja y apoyar la toma de decisiones estratégicas, pero su adopción aún es marginal en el país (Gaertner et al., 2024). Esto revela una brecha significativa entre el potencial de las tecnologías y su implementación práctica en el contexto de las PYMEs colombianas.

En el plano conceptual, la analítica predictiva, el business intelligence (BI) y la inteligencia financiera conforman un triángulo estratégico para la sostenibilidad de las PYMEs. Mientras la analítica predictiva provee la capacidad de anticipación, BI ofrece la infraestructura de datos necesaria y la inteligencia financiera traduce los resultados en indicadores accionables

para la gestión. Sin embargo, estudios recientes destacan que la adopción de BI y analítica en PYMEs está condicionada por limitaciones económicas, falta de competencias digitales y barreras culturales frente a la innovación (Valarezo et al., 2021).

Los modelos y teorías revisados refuerzan esta tensión entre el potencial teórico y la realidad organizacional. Por un lado, el modelo Altman Z-score y sus variantes muestran cómo, desde hace décadas, existen intentos de predecir la quiebra empresarial a través de ratios financieros. No obstante, investigaciones recientes concluyen que los modelos basados en ML ofrecen mayor precisión, aunque a costa de requerir más datos y capacidades tecnológicas (Wasserbacher & Spindler, 2021). Por otro lado, teorías de adopción tecnológica como TAM, DOI y el marco TOE explican que la aceptación de herramientas de analítica depende no solo de su utilidad y facilidad de uso percibida, sino también del entorno regulatorio, la cultura organizacional y la infraestructura disponible (Tay & Shen, 2023). Esto implica que el éxito de implementar analítica predictiva en PYMEs requiere un enfoque integral que trascienda lo técnico y considere la dinámica organizacional.

En el contexto normativo, Colombia cuenta con instrumentos legales que favorecen la adopción de tecnologías, como la Ley 2069 de 2020 y las políticas del CONPES 3920 (2018) y 4011 (2020), además de la obligatoriedad de aplicar NIIF para PYMEs. Estos marcos, junto con regulaciones internacionales como los acuerdos de Basilea, establecen un terreno fértil pero aun insuficientemente aprovechado para la transformación digital de las pequeñas y medianas empresas.

De esta forma, puede afirmarse que la literatura presenta tres grandes vacíos: 1. la falta de estudios empíricos aplicados específicamente a PYMEs colombianas en materia de analítica predictiva financiera; 2. la escasa integración de marcos teóricos de adopción tecnológica con modelos financieros predictivos; y 3. la necesidad de metodologías prácticas y accesibles que reduzcan la brecha entre los estándares internacionales y las capacidades reales de las empresas locales.

En consecuencia, la presente investigación se justifica no solo por el potencial de la analítica predictiva para fortalecer la inteligencia financiera de las PYMEs, sino también por la necesidad de proponer lineamientos estratégicos que articulen teoría, práctica y normatividad. Este enfoque busca generar un impacto en la competitividad y sostenibilidad de las empresas, al tiempo que contribuye al debate académico sobre la aplicabilidad de la analítica avanzada en contextos emergentes.

Enfoque, Alcance y Diseño de la Investigación

Según Hernández et al. (2014), una investigación cualitativa busca comprender fenómenos desde la perspectiva de los participantes, es por ello, que para esta investigación se adopta un enfoque cualitativo con respaldo documentado, enfocado en comprender las percepciones y dinámicas que influyen en la adopción de técnicas de Machine Learning en las PYMES en Colombia, explorando a través de una entrevista la perspectiva de los actores o dueños del negocio, aspectos como:

- Resistencia al cambio.

- Capacidad organizacional (habilidades técnicas y talento humano).
- Limitaciones económicas.
- Dinámicas de decisión entorno a los datos.
- Calidad de los datos.
- Experiencias previas.
- Contexto regulatorio.
- Visión a largo plazo.

Alcance y Diseño

- a) El diseño corresponde a un estudio de tipo no experimental, ya que de acuerdo con Kerlinger y Lee (1999), no hay manipulación de variables ni se desarrollan intervenciones sobre empresas, si no que se observa fenómenos tal como ocurren en realidad.
- b) Es de carácter transversal debido a que la recolección de datos se realizará en un único momento, ofreciendo una visión instantánea de la situación actual (Kerlinger & Lee, 1999).
- c) Se define como una investigación:
 - a. Descriptiva, donde se buscamos caracterizar las prácticas, limitaciones y experiencias de las PYMEs frente al uso de analítica predictiva.
 - b. Aplicada: ya que partir de estos hallazgos, se propondrán directrices prácticas y estratégicas para fortalecer la inteligencia financiera.

Definición de Variables

Resulta necesario precisar las variables y dimensiones que orienta en estudio de esta investigación con el fin de garantizar validez teórica, relevancia practica y replicabilidad. Según Hernández et al. (2014), la definición de variables en un estudio académico corresponde a dos niveles:

1. Definición conceptual, que corresponde a explicar la variable desde la teoría o literatura científica.
2. Definición operacional que responde a como se va a medir o analizar la investigación.

De acuerdo con lo expuesto, presentan las principales variables de estudio:

Tabla 2*Variables de estudio.*

Variable	Definición conceptual	Definición operacional	Preguntas de las entrevistas
¿Qué está pasando en mi empresa?	La analítica descriptiva se centra en recopilar y organizar datos históricos, aplicando procesos de agregación y visualización que permiten interpretar y explicar el desempeño pasado y la situación actual de la organización. (Aguilar, 2019)	- Validación de reportes financieros y el balance general de la empresa. - Controles de calidad en la información recopilada. - Aplicación de un sistema de Gobernanza de Datos.	
¿Qué podría pasar en mi empresa?	“Es la aplicación de técnicas matemáticas y estadísticas avanzadas, así como el aprendizaje automático (machine learning), para predecir datos necesarios pero que no se visualizan directamente y están ausentes.” (Aguilar, 2019, p. 80.)	Identificación de técnicas aplicadas de los modelos estadístico de series temporales para hacer pronósticos como: Arima, Holt-Winters.	
¿Qué necesito hacer para que pase en mi empresa?	De acuerdo con Aguilar (2019), la analítica prescriptiva “es la parte de la analítica que se dedica a la automatización de la toma de decisiones”. (p. 81)	- Simulación de escenarios financieros. - Modelos de planeación y optimización de recursos. - Alertas tempranas para anticipar situaciones críticas.	
Gestión Financiera	“Cómo obtener y utilizar de manera óptima los recursos de una compañía. Abarca la planificación, organización, control y monitoreo de los recursos	- Entrevistas a dueños de PYMES donde podamos identificar: - Herramientas de planeación.	¿Qué tipos de datos financieros y operativos recopila su empresa actualmente?

	financieros para alcanzar los objetivos de la empresa.” (Westreicher, 2020)	• Indicadores financieros aplicados. • Mecanismos de control. • Proceso para la toma de decisiones.	• ¿Qué factores considera que facilitan o dificultan la adopción de tecnologías analíticas en su empresa? • ¿Qué métricas o métodos sugiere para validar un modelo en contexto PYME? • ¿Qué prácticas de gobernanza y ética recomienda implementar en proyectos de ML?
Riesgo Financiero	Ludeña (2021), sostiene que “el riesgo financiero es la probabilidad de que se produzca un acontecimiento negativo que provoque pérdidas financieras en una empresa” (Ludeña, 2021).	• Entrevistas a dueños de PYMES donde podamos identificar indicadores clave como: • Incumplimiento de pagos. • Acceso al crédito • Cambios regulatorios.	• ¿Qué riesgos o preocupaciones tendría frente a la implementación de estas tecnologías? • Desde su perspectiva, ¿cómo puede el Machine Learning contribuir a la gestión del riesgo financiero en las PYMEs?

Inteligencia de negocios	Como lo plantea Avila et al. (2021), la inteligencia de negocios es un sistema de apoyo estratégico que permite analizar e interpretar grandes volúmenes de datos financieros, transformándolos en información útil para la toma de decisiones empresariales.	• Aplicación de tableros de control a través de herramientas como Power BI. • Monitoreo de KPI claves.	• ¿Qué beneficios concretos cree que traería un sistema de analítica predictiva para su negocio? • ¿Cómo recomienda integrar modelos predictivos dentro de tableros BI para aportar valor operativo?
Crecimiento sostenible	Se entiende como la habilidad de una organización para expandir sus ingresos y utilidades, preservando al mismo tiempo su solidez financiera y manteniendo prácticas en sus tres pilares sostenibles. Económico, social y ambiental. (Higgins, 1977)	• Casos de éxito de la implementación de ML apoyó un crecimiento entre ingresos y operaciones. • Entrevistas a expertos en ML.	• ¿Puede contarnos un caso en que una predicción o dato influyó en una decisión importante? ¿Cuál fue el resultado? • ¿Podría mencionar un caso exitoso donde ML haya generado impacto en finanzas de PYMEs o empresas similares? • ¿Qué arquitectura o herramientas recomendaría para

			comenzar en una PYME con recursos limitados? • ¿Qué pasos concretos debería seguir una PYME en los próximos 6 meses para avanzar en inteligencia financiera con analítica predictiva? • ¿Podría recomendar lecturas, recursos o casos útiles para esta investigación?
Adopción del ML	La adopción de la tecnología puede analizarse desde dos marcos: el TOE, que plantea que la innovación tecnológica está condicionada por factores tecnológicos, organizacionales y del entorno, lo que permite una visión integral y aplicable a empresas de distintos tamaños (Tornatzky & Fleischer, 1990). Y el TAM, que explica la aceptación individual de la tecnología a partir de la utilidad percibida y la facilidad de uso percibida. (Davis, 1989)	• Percepciones en las entrevistas a dueños de PYMES. • Entrevistas a expertos en ML.	• ¿Han probado o usan herramientas para el análisis de datos o predicción? ¿Para qué procesos? • ¿Qué tipo de apoyo considera necesario para adoptar este tipo de herramientas (formación, asesoría, financiación)? • ¿Cómo visualiza la gestión financiera de su empresa dentro de 3–5

años si integrara
analítica predictiva?

- Desde su experiencia, ¿cuáles son los factores técnicos y organizacionales que determinan la adopción o resistencia de ML en PYMEs?
 - ¿Qué modelos o técnicas considera más viables para predicción financiera en PYMEs?
-

Nota: la tabla presenta las variables y dimensiones de estudio.

Tamaño y Selección de Muestra

La definición del tamaño y tipo de muestra constituye una decisión clave dentro del diseño metodológico, ya que determina el alcance, la validez y la profundidad del estudio. En el presente proyecto, la población de referencia está conformada por las pequeñas y medianas empresas (PYMEs) que operan en el territorio colombiano, entendidas conforme a la clasificación establecida por la Ley 905 de 2004 y la Ley 2069 de 2020, las cuales consideran el número de empleados y los niveles de ingresos como criterios de clasificación. Estas empresas representan un componente fundamental del aparato productivo nacional, al concentrar más del 90 % de las unidades empresariales formales y ser responsables de una alta proporción del empleo en el país (Confecámaras, 2023).

Dado que el estudio tiene un enfoque cualitativo y exploratorio, su propósito no es generalizar resultados a toda la población de PYMEs colombianas, sino comprender en profundidad las dinámicas, percepciones y desafíos asociados a la adopción de analítica predictiva como herramienta para fortalecer la inteligencia financiera. En este sentido, el criterio de selección de la muestra no se basa en la representatividad estadística, sino en la pertinencia y riqueza informativa de las fuentes y actores elegidos, lo que se alinea con los principios de la investigación cualitativa según algunos autores (Creswell & Poth, 2018).

En coherencia con este enfoque, se opta por un muestreo no probabilístico de tipo intencional o por criterio (*purposive sampling*), el cual permite seleccionar deliberadamente a los participantes y documentos que poseen un conocimiento profundo y especializado sobre el fenómeno de estudio. Este tipo de muestreo es especialmente adecuado cuando el interés del

investigador se centra en explorar significados, patrones y experiencias, más que en obtener resultados generalizables a toda la población (Flick, 2014)

La muestra se conformará por dos grupos principales de análisis, que permitirán la triangulación de la información.

Entrevistas Semiestructuradas a Dueños de PYMEs y Expertos (n=3)

Se entrevistará a un grupo reducido de líderes y empresarios de PYMEs colombianas, seleccionados por su participación activa en la gestión financiera y en la toma de decisiones estratégicas dentro de sus organizaciones. La inclusión no dependerá de que las empresas utilicen actualmente herramientas de machine learning, sino de su potencial para aportar información sobre el grado de conocimiento, adopción o ausencia de estas tecnologías en su gestión empresarial. Esta diversidad permitirá contrastar percepciones y experiencias entre quienes ya han incorporado soluciones analíticas y quienes aún no lo han hecho, proporcionando una visión integral del estado de adopción tecnológica en el sector.

El número estimado de participantes será de tres empresarios o directivos, cantidad suficiente para alcanzar la saturación teórica, entendida como el punto en el que la incorporación de nuevas entrevistas no aporta información sustancialmente diferente o relevante para los objetivos del estudio (Strauss, 1998).

Análisis Documental (n=15)

El corpus documental incluirá literatura científica, informes institucionales, políticas públicas, y normatividad vigente relacionada con la analítica predictiva y la gestión financiera en PYMEs. Entre las fuentes se contemplan artículos académicos, informes del Ministerio de Comercio, Industria y Turismo, Confecámaras, la OCDE y organismos multilaterales. Los documentos se seleccionarán en función de su relevancia temática, actualidad (últimos diez años, con énfasis en el período 2023–2025), y credibilidad de la fuente (publicaciones indexadas o institucionales).

Esta estrategia de muestreo busca equilibrar la profundidad analítica y la diversidad informativa, garantizando la inclusión de perspectivas tanto teóricas como prácticas. No se recurre a un censo, dado que este implicaría abarcar la totalidad de las PYMEs en Colombia, lo cual resultaría inviable en términos logísticos, temporales y financieros. Además, la naturaleza exploratoria del estudio justifica la elección de una muestra reducida pero altamente informada, que permita generar conocimiento transferible más que generalizable, en línea con los postulados de Lincoln y Guba (Lincoln, 1985) sobre la validez en la investigación cualitativa.

El proceso de selección se guiará por criterios claramente definidos:

Para expertos dueños de PYMEs: trayectoria en el campo de la analítica financiera, gestión de datos o transformación digital; participación en proyectos o investigaciones aplicadas al contexto empresarial colombiano; y disponibilidad para participar voluntariamente en entrevistas semiestructuradas.

Para documentos: pertinencia con los ejes temáticos del estudio (gestión financiera, analítica predictiva, adopción tecnológica y riesgo empresarial), fecha de publicación reciente y confiabilidad de la fuente.

De esta forma, el tamaño y tipo de muestra responden a la necesidad de obtener información rica, relevante y contextualizada, que permita construir lineamientos estratégicos sólidos y aplicables al contexto nacional. La combinación del análisis documental con las entrevistas a expertos posibilitará la triangulación de resultados, aumentando la validez y confiabilidad de los hallazgos (Creswell & Poth, 2018). La convergencia entre ambas fuentes servirá de base para proponer recomendaciones integradas que fortalezcan la inteligencia financiera de las PYMEs colombianas mediante el uso de la analítica predictiva.

Selección de Métodos o Instrumentos para la Recolección de Información

Para la presente investigación se emplearán dos instrumentos principales de recolección de información: el análisis documental y las entrevistas semiestructuradas. Ambos métodos son complementarios, ya que permiten integrar la revisión teórica con la evidencia empírica derivada de la experiencia directa de los actores empresariales.

En primer lugar, el análisis documental se realizará a través de una matriz de revisión de literatura, que permitirá sistematizar y comparar estudios previos sobre la adopción de herramientas de *machine learning* en PYMEs, su impacto en la gestión financiera y los factores que inciden en su implementación. Esta técnica facilita la identificación de patrones, vacíos de conocimiento y enfoques teóricos relevantes (Bowen, 2009). Además, el análisis documental

contribuye a contextualizar los resultados de las entrevistas dentro de un marco conceptual sólido.

En segundo lugar, se aplicarán entrevistas semiestructuradas dirigidas a líderes y empresarios de PYMEs, con el fin de explorar sus percepciones, experiencias y actitudes frente al uso de tecnologías analíticas. Este instrumento es pertinente porque combina una estructura flexible con la posibilidad de profundizar en los temas emergentes durante la conversación (Creswell & Poth, 2018). Asimismo, permite captar la complejidad de los procesos organizacionales y las barreras culturales o técnicas que influyen en la adopción tecnológica (Kvale, 2007).

La elección de estos instrumentos se justifica porque ambos proporcionan información cualitativa de alta riqueza interpretativa, alineada con los objetivos del estudio, que buscan comprender las motivaciones, limitaciones y percepciones asociadas a la digitalización y el uso de *machine learning* en PYMEs colombianas.

Técnicas de Análisis de Datos

La etapa de análisis de datos constituye un componente esencial en el desarrollo de toda investigación, ya que permite transformar la información recolectada en hallazgos que aporten respuestas a la pregunta de investigación y a los objetivos formulados. Ahora bien, en este proyecto el enfoque es cualitativo y de carácter exploratorio, para esto, se emplearán técnicas de análisis orientadas a la interpretación de información documental y entrevistas a expertos, con el

propósito de generar lineamientos estratégicos que fortalezcan la inteligencia financiera de las PYMEs colombianas mediante la analítica predictiva.

De acuerdo con Creswell y Poth (2018), la coherencia entre el diseño metodológico, los instrumentos de recolección y las técnicas de análisis asegura que los resultados obtenidos sean válidos, fiables y útiles para la toma de decisiones. En este caso, el estudio opta por dos instrumentos principales: la revisión documental y las entrevistas semiestructuradas. A partir de ellos se definen técnicas de análisis específicas, propias del enfoque cualitativo: el análisis de contenido y la codificación cualitativa con base en el análisis temático.

Consideraciones sobre Técnicas de Análisis de Datos en Investigación Cualitativa y Cuantitativa

Las técnicas de análisis varían sustancialmente según el enfoque de investigación. En los estudios cuantitativos, se privilegia el uso de herramientas estadísticas como la estadística descriptiva, la inferencia estadística, el análisis de regresión o los modelos predictivos, que buscan establecer relaciones causales o correlaciones entre variables (Liu et al., 2023). Por ejemplo, en el campo financiero, el uso de modelos ARIMA o Holt-Winters constituye una técnica cuantitativa que permite proyectar series temporales y estimar tendencias en variables como flujo de caja o ventas (Wasserbacher & Spindler, 2022).

Por el contrario, en investigaciones de tipo cualitativo, como la presente, el análisis se centra en comprender significados, patrones y percepciones. Entre las técnicas más utilizadas destacan:

- **Análisis de contenido:** Transformación de información textual en categorías sistemáticas (Krippendorff, 2018).
- **Teoría fundamentada (Grounded Theory):** Construcción de categorías emergentes y teoría a partir de los datos recolectados (Charmaz, 2014).
- **Análisis del discurso:** Estudio de cómo el lenguaje refleja estructuras de poder, ideologías o percepciones sociales (Gee, 2014).
- **Análisis temático:** Identificación de patrones o temas recurrentes en el material recolectado (Braun & Clarke, 2006).

En este proyecto, dada la combinación de análisis documental y entrevistas, se empleará el análisis de contenido y el análisis temático, complementados por procesos de codificación cualitativa. Estos métodos permiten generar una visión integrada de los documentos normativos y académicos revisados, así como de las percepciones de expertos en ML y gestión financiera en PYMEs.

Análisis Documental: Técnica de Análisis de Contenido

El análisis documental se abordará mediante la técnica de análisis de contenido, definida como un procedimiento sistemático para examinar textos con el fin de identificar categorías, patrones y significados (Neuendorf, 2017). En el contexto de esta investigación, los documentos incluyen:

- Literatura académica sobre analítica predictiva y PYMEs.

- Informes institucionales de entidades como Confecámaras o el Ministerio de Comercio.
- Normatividad relevante (NIIF para PYMEs, Ley 2069 de 2020, Ley 1581 de 2012).

El análisis de contenido permitirá organizar la información documental en categorías alineadas con las variables definidas previamente: analítica predictiva, gestión financiera, riesgo, crecimiento sostenible y adopción de ML.

El procedimiento que seguir contempla tres etapas (Krippendorff, 2018):

1. **Selección del corpus documental:** Se definirán los textos clave a analizar, incluyendo artículos científicos, leyes, informes técnicos y documentos institucionales.
2. **Codificación de contenido:** Se asignarán etiquetas o códigos a fragmentos de texto que correspondan a las variables de estudio. Por ejemplo, menciones a "riesgo de liquidez" se codificarán bajo la categoría de gestión del riesgo financiero.
3. **Categorización y síntesis:** Los códigos se agruparán en categorías más amplias, que permitirán derivar lineamientos estratégicos sobre cómo aplicar la analítica predictiva a la gestión financiera de las PYMEs.

Este enfoque ha demostrado ser eficaz en investigaciones aplicadas a la adopción tecnológica en PYMEs, pues facilita la construcción de lineamientos claros a partir de fuentes diversas (Nam, Lee, & Lee, 2019).

Análisis de Entrevistas: Codificación Cualitativa y Análisis Temático

Las entrevistas semiestructuradas con expertos en machine learning, finanzas y gestión de PYMEs serán analizadas mediante un proceso de codificación cualitativa, apoyado en el enfoque de análisis temático (Braun & Clarke, 2006).

Este procedimiento comprende:

- **Codificación abierta:** Identificación inicial de conceptos clave en las respuestas de los entrevistados.
- **Codificación axial:** Relación entre códigos y agrupación en categorías más generales (ejemplo: "barreras de adopción", "beneficios estratégicos", "limitaciones técnicas").
- **Codificación selectiva:** Integración de las categorías en lineamientos estratégicos aplicables al contexto de las PYMEs colombianas.

El análisis temático permite ir más allá de la literalidad del discurso y explorar significados subyacentes, percepciones compartidas o divergentes y tensiones entre lo ideal y lo real en la adopción de tecnologías analíticas (Saldaña, 2021).

Triangulación de Resultados

La validez de los hallazgos se garantizará mediante la triangulación de fuentes, es decir, la comparación entre resultados obtenidos del análisis documental y del análisis de entrevistas. Creswell y Poth (2018) sostienen que la triangulación incrementa la confiabilidad en estudios cualitativos al reducir sesgos derivados de un solo tipo de fuente. En este caso, los lineamientos

finales se construirán únicamente cuando exista convergencia entre la evidencia documental y las percepciones expertas.

Tabla 3

Tabla de Instrumentos, Técnicas y Descripción.

Instrumento	Técnica de análisis	Descripción
Análisis documental	Análisis de contenido	Revisión sistemática de literatura científica, informes y normatividad; categorización en lineamientos estratégicos para las PYMEs.
Entrevistas semiestructuradas	Codificación cualitativa / Análisis temático	Identificación de patrones y temas en percepciones de expertos; construcción de categorías que sustenten lineamientos estratégicos.

Nota: la tabla presenta los instrumentos y técnicas cualitativas utilizadas para analizar la información recolectada.

Relación de Técnicas con los Objetivos de Investigación

Las técnicas seleccionadas permiten responder directamente a los objetivos específicos planteados:

- (Identificar limitaciones en gestión de datos): el análisis documental permitirá evidenciar brechas normativas, tecnológicas y culturales.
- (Explorar técnicas de analítica predictiva): la codificación cualitativa de entrevistas revelará la aplicabilidad de modelos como ARIMA o ML en PYMEs.
- (Evaluar beneficios y desafíos de modelos predictivos): la triangulación entre fuentes permitirá contrastar beneficios reportados en la literatura con experiencias en Colombia.

- (Proponer lineamientos estratégicos): el análisis temático integrará hallazgos en propuestas viables para las PYMEs.

Extensión de Resultados Esperados

Se espera que la aplicación rigurosa de estas técnicas permita generar hallazgos como:

- Una tabla categorizada de los principales retos de las PYMEs en Colombia para adoptar analítica predictiva.
- La identificación de patrones en los discursos de expertos sobre barreras (costos, cultura organizacional, infraestructura tecnológica).
- La construcción de lineamientos estratégicos basados en la convergencia entre literatura y práctica, que puedan ser aplicados en contextos reales de gestión financiera en PYMEs.

Reporte de Resultados

Análisis Documental

A partir de la técnica de análisis de contenido, se presentan los principales resultados:

Tabla 4.

Análisis documental.

Título del Estudio	País	Año	Descripción	Código	Categoría
Implementación de Machine Learning en el Centro de Competencias de Inteligencia Artificial de Bancolombia	Colombia	2024	Optimización de procesos financieros y detección de fraudes con IA	Optimización de procesos	Gestión del riesgo financiero
Aplicación de Machine Learning y Analítica Avanzada en el Ecosistema de Rappi	Colombia	2024	Personalización y predicción de demanda en plataformas digitales	Comportamiento del cliente	Estrategias de crecimiento y rentabilidad
Implementación de Machine Learning en Nubank para la Optimización del Riesgo Crediticio	Perú	2023	Modelos predictivos de riesgo y personalización financiera	Modelos predictivos	Inclusión y análisis financiero
Transformación mediante Machine Learning en Grupo Aval	Colombia	2023	IA para gestión del riesgo y eficiencia operativa	Transformación digital	Cultura de datos y gestión financiera
Addi: Crédito instantáneo y evaluación automatizada con Machine Learning	Colombia	2025	Crédito digital y automatización fintech	Modelos predictivos	Innovación financiera y acceso al crédito
Economía del Dato para PYMEs: Claves para Impulsar los Negocios	Latinoamérica (Colombia, Uruguay, El Salvador)	2024	Uso de datos y herramientas accesibles para decisiones ágiles	Analítica	Transformación digital y analítica básica
Propuesta de Modelo de Analítica para Flujo de Caja en MIPYMES en Colombia	Colombia	2024	Predicción de flujo de caja con modelos de analítica	Modelos predictivos	Gestión de liquidez y planeación financiera
Modelo de Predicción de Default en PYMEs de Medellín	Colombia	2025	Predicción de incumplimiento crediticio con ML	Modelos predictivos	Análisis de riesgo financiero

Inteligencia Artificial para la Toma de Decisiones en PYMEs Colombianas	Colombia	2024	Aplicación de IA para decisiones estratégicas y operativas	Adopción de IA	Competitividad y eficiencia operativa
Implementación de un Sistema de IA para la Gestión de Cartera en PYMEs de Medellín	Colombia	2025	Automatización de cobranza y análisis predictivo	Adopción de IA	Sostenibilidad financiera
Adopción de Tecnologías Financieras y Alfabetización Financiera en PYMEs Camerunesas	Camerún	2023	FinTech y educación financiera post COVID-19	Adopción de IA	Alfabetización financiera y resiliencia
Adopción de Tecnologías Financieras y su Influencia en el Acceso al Crédito Bancario	Asia / Medio Oriente	2023	Digitalización financiera y acceso al crédito	Digitalización crediticia	Inclusión y sostenibilidad financiera
Decisiones Empresariales Basadas en Datos en PYMEs del Reino Unido	Reino Unido	2024	Cultura de datos y decisiones analíticas	Analítica	Gestión basada en datos
Aplicación de la Inteligencia Artificial en la Toma de Decisiones Financieras en PYMEs de Nigeria	Nigeria	2024	IA para decisiones financieras y eficiencia operativa	Adopción de IA	Productividad y toma de decisiones
Modelos Predictivos Basados en Inteligencia Artificial para la Gestión Financiera en PYMEs	África y Asia	2024	IA y ML en modelos de riesgo y predicción financiera	Modelos predictivos	Inteligencia financiera y analítica predictiva

Nota: la tabla presenta los resultados obtenidos a partir de la recopilación de los documentos técnicos.

Análisis de Entrevistas

A partir de la codificación cualitativa y el análisis temático de las entrevistas realizadas, se presentan los siguientes resultados:

Tabla 5.

Análisis de entrevistas.

Nombre del entrevistado	Tipo de entrevista	Codificación abierta	Codificación axial	Codificación selectiva
Maikol Bonilla Gil	Empresario	• Uso de herramientas analíticas (Firebase, BigQuery, Data Studio) • Cultura data-driven. • Falta de especialistas • Costos de herramientas • Interés en predicción de abandono • ROI	• Adopción tecnológica y cultura organizacional. • Beneficios de analítica predictiva. • Barreras de implementación.	Fomentar una cultura analítica en las PYMEs mediante formación técnica y asesoría estratégica que permita integrar modelos predictivos para decisiones financieras.
Rene Ricardo Contreras Rodríguez	Empresario	• Implementación de CRM sin capacidad predictiva • Decisiones basadas en experiencia	• Barreras de adopción y madurez digital.	Las PYMEs deben iniciar con analítica descriptiva, fortalecer la alfabetización en datos y evaluar gradualmente el retorno de la inversión en herramientas predictivas.

		• Necesidad de formación. • Dificultad para medir ROI. • Uso de herramientas libres.	• Formación técnica como factor habilitante. • Retos de medición de impacto.	
Mauricio Rojas	Empresario	• Uso básico de Power BI y Excel • Desconocimiento de ML • Necesidad de incentivos gubernamentales • Interés en optimización de inventarios y costos	• Limitaciones técnicas y financieras. • Rol del Estado en la transformación digital. • Visión de mejora operativa	Promover políticas públicas y programas de apoyo para capacitación e incentivos fiscales que impulsen la adopción de analítica predictiva en PYMEs industriales.
Andrés Felipe Cruz Salinas	Experto	• Acceso a datos como clave del éxito • Recomendación de modelos lineales y XGBoost • Importancia de métricas de validación y ética. • Visualización en Business Intelligence con intervalos de confianza.	• Factores técnicos y éticos de adopción. • Modelos predictivos apropiados para PYMEs.	Impulsar la implementación responsable de modelos predictivos simples, validados con métricas claras y acompañados de prácticas éticas y de gobernanza de datos.

Patricia Cifuentes	Experto	• Confusión entre compra de software y creación de capacidades • Necesidad de madurez estadística • Ética y gobernanza. • Uso de herramientas libres. • Moda de la Inteligencia Artificial.	• Capacidades institucionales y éticas. • Gobernanza de datos. • Fases de madurez tecnológica.	La adopción de ML debe basarse en la construcción progresiva de capacidades analíticas, gobernanza ética y uso eficiente de tecnologías abiertas.
Diego Mora	Experto	• Limitaciones de recursos • Modelos de regresión como opción viable. • Integración de ML en Power BI. • Prevención de fraude. • Sesgos.	• Limitaciones tecnológicas y financieras. • Aplicaciones prácticas del ML. • Gestión ética y de riesgos.	Fomentar la adopción gradual de modelos simples dentro de entornos de Business Intelligence, fortaleciendo la calidad de datos y la ética organizacional.

Nota: la tabla presenta los resultados del análisis a las entrevistas realizados a empresarios y expertos.

Principales Retos para la Adopción de Analítica Predictiva en PYMEs Colombianas

A partir del análisis documental y de las entrevistas realizadas, se presentan los principales retos categorizados e impactos que generan sobre la adopción de analítica predictiva en las PYMEs:

Tabla 6.

Principales Retos para la Adopción de Analítica Predictiva en PYMEs Colombianas

Categoría	Reto	Impacto
Técnica	• Falta de infraestructura tecnológica adecuada como: servidores, almacenamiento en la nube, integración de sistemas. • Calidad, disponibilidad, integridad de los datos. • Desconocimiento sobre herramientas libres o accesibles como Python, Power Bi, RStudio.	• Dificulta la automatización de procesos y el entrenamiento de modelos de ML, siendo poco confiables y resultando proyecciones inexactas. • Bajo uso de tecnologías disponibles de bajo costo.
Organizacional	• Falta de cultura orientada a decisiones basadas en datos. • Prioridad de recursos hacia la operación frente a innovación analítica. • Ausencia de liderazgo digital o visión analítica.	• Resistencia interna a la implementación de modelos analíticos, siendo considerada no estratégica.
Financiera	• Los costos iniciales para la adopción de ML son percibidos como altos (consultorías, licencias, capacitación). • Dificultad para medir el retorno de inversión (ROI) de la analítica.	• Desincentiva la inversión en proyectos analíticos. • Falta de evidencia económica para justificar proyectos analíticos

Cultural y de conocimiento	• Escaso conocimiento de estadística y digital en los equipos. • Miedo o desconfianza hacia la automatización.	• Implementaciones superficiales sin resultados medibles. • Baja adopción o rechazo a los modelos predictivos.
Regulatoria y ética	• Dudas sobre protección de datos personales y cumplimiento normativo. • Ausencia de lineamientos nacionales claros sobre ética e IA para PYMEs.	• Riesgo de mal uso de los datos.
Talento humano	• Falta de perfiles técnicos en ciencia de datos o Business Intelligence. • Falta formación a los equipos de trabajo.	• Dependencia de externos. • Brecha entre las capacidades de las PYMEs y los requerimientos tecnológicos.

Nota: la tabla presenta los principales retos e impactos en las PYMEs del análisis a las entrevistas realizados a empresarios y expertos.

Barreras para la Adopción de la Analítica Predictiva

Se analizaron tres entrevistas semiestructuradas realizadas a profesionales con experiencia en desarrollo tecnológico, ciencia de datos y gestión empresarial. Las categorías de análisis se centraron en tres dimensiones clave: costos, cultura organizacional e infraestructura tecnológica.

Costos y Recursos Financieros

Uno de los patrones más evidentes entre los tres discursos es la percepción de los costos de adopción como un obstáculo estructural. Los expertos coinciden en que la implementación de

soluciones de Machine Learning implica una inversión inicial significativa, especialmente en etapas tempranas de desarrollo organizacional.

El CTO de Bitsquid SAS, Maikol Bonilla señala que las herramientas analíticas y los servicios de consultoría especializados pueden representar gastos considerables, lo que obliga a priorizar el desarrollo de producto sobre proyectos de analítica avanzada. De forma complementaria, la segunda experta, Patricia Cifuentes de perfil técnico e investigador enfatiza la necesidad de comenzar con modelos simples y de bajo costo computacional, como la regresión lineal o el uso de librerías ligeras (por ejemplo, *Pandas*), antes de invertir en infraestructura compleja.

En una línea convergente, el tercer entrevistado, Diego Mora destaca que las restricciones financieras son una de las causas más frecuentes de resistencia en las PYMEs, ya que el aumento del volumen de datos requiere mayor capacidad de procesamiento y almacenamiento, incrementando los costos operativos.

En conjunto, los discursos reflejan una visión pragmática: las inversiones deben ser progresivas y guiadas por el retorno sobre la inversión (ROI), priorizando la demostración de valor antes de escalar hacia soluciones más avanzadas.

Cultura Organizacional y Talento Humano

En cuanto a la dimensión cultural, los tres expertos resaltan que la mentalidad organizacional y las competencias del personal determinan en gran medida el éxito o fracaso de los proyectos de ML.

Maikol Bonilla sostiene que la cultura de su empresa, orientada a la toma de decisiones basada en datos, facilita la adopción tecnológica; no obstante, reconoce como limitante la escasez de especialistas en ciencia de datos dedicados exclusivamente a tareas analíticas. Por su parte, Patricia Cifuentes enfatiza en la importancia de establecer protocolos claros de evaluación y separación de roles (entrenamiento versus validación) para evitar sesgos, además de fomentar una cultura ética y responsable en el manejo de datos.

Por su parte, el Diego Mora vincula la cultura organizacional con la alfabetización en datos: los empleados deben comprender la relevancia de la calidad, la transparencia y la confidencialidad de la información. Desde esta perspectiva, la adopción de ML no depende únicamente de la disponibilidad tecnológica, sino también del compromiso humano con las prácticas éticas y la gestión responsable del conocimiento.

Se evidencia así un patrón compartido: la falta de capital humano especializado y de una cultura data-driven son barreras tan relevantes como las limitaciones financieras o técnicas.

Infraestructura Tecnológica

En relación con la infraestructura tecnológica, los discursos muestran consenso en que las PYMEs enfrentan restricciones de capacidad técnica, tanto a nivel de procesamiento como de integración de datos.

El experto de Bitsquid SAS identifica su infraestructura en la nube (Google Cloud, Firebase) como un facilitador, aunque admite que la falta de personal especializado limita la profundidad del análisis. Cifuentes recomienda a las PYMEs iniciar con arquitecturas sencillas y

escalables, evitando frameworks complejos hasta justificar su adopción mediante resultados medibles. Finalmente, Mora advierte que el manejo de grandes volúmenes de información puede provocar errores y desajustes en modelos si la infraestructura no es adecuada, lo que repercute directamente en la eficiencia y confiabilidad del proceso analítico.

Por lo tanto, existe una visión compartida: la infraestructura debe desarrollarse de manera escalonada y proporcional al crecimiento del negocio, priorizando herramientas accesibles y soluciones basadas en la nube que minimicen la inversión inicial.

El análisis comparativo de los tres discursos permite identificar un patrón coherente de barreras interrelacionadas. Los costos elevados, la carencia de talento especializado y las limitaciones tecnológicas se configuran como los principales obstáculos para la implementación de Machine Learning en PYMEs.

Sin embargo, los expertos también coinciden en que estas barreras pueden mitigarse mediante una estrategia gradual, que combine modelos simples, infraestructura escalable y capacitación interna. Además, subrayan que el éxito de la adopción tecnológica no solo depende de la inversión económica, sino también de la madurez organizacional y la cultura analítica que respalde la toma de decisiones basada en datos.

Construcción de Lineamientos Estratégicos Basados en la Convergencia entre Literatura y Práctica, Aplicables en Contextos Reales de Gestión Financiera en PYMEs

El presente apartado sintetiza los lineamientos estratégicos derivados de la triangulación entre (a) la revisión teórica sobre analítica predictiva y adopción tecnológica, (b) los casos de estudio revisados (Anexo 3) y (c) las entrevistas realizadas a empresarios (Anexo 4) y a expertos en machine learning (Anexo 5). La interpretación de los datos siguió el procedimiento de análisis de contenido con codificación temática, lo cual permitió identificar categorías recurrentes que convergen con los referentes teóricos seleccionados.

De la literatura consultada se reconoce que la adopción de analítica predictiva en PYMEs depende de la interacción entre tres dimensiones: infraestructura tecnológica, cultura organizacional y capacidades analíticas (Ali, 2024; Tay & Shen, 2023). Los datos empíricos (Anexo 3, Anexo 4 y Anexo 5) corroboran esta estructura y aportan matices prácticos: los empresarios privilegian soluciones de rápida aplicación y bajo costo, mientras los expertos enfatizan la necesidad de gobernanza de datos y de una ruta de adopción gradual. Sobre esa base se proponen los siguientes lineamientos estratégicos aplicables en contextos reales de gestión financiera en PYMEs colombianas.

1. Adopción progresiva y priorización de valor temprano.

Se recomienda comenzar con herramientas accesibles y de alto impacto inmediato (por ejemplo, Microsoft Excel, Google Sheets y dashboards en Power BI) para resolver problemas concretos como proyección de flujo de caja y monitorización de indicadores críticos. Esta ruta

incremental validada por la literatura y por los expertos consultados (Anexo 5) permite demostrar valor a corto plazo, reducir la resistencia interna y crear evidencia práctica que justifique inversiones posteriores en modelos predictivos más sofisticados (González et al., 2024; Tay & Shen, 2023).

2. Fortalecimiento de la gobernanza y calidad de datos.

La implementación de protocolos de recolección, limpieza, documentación y seguridad de los datos financieros es una condición habilitante para cualquier proyecto predictivo. Los expertos (Anexo 5) y la literatura señalan que sin gobernanza los modelos generan resultados poco confiables; por tanto, se sugiere la definición de roles (responsable de datos), procedimientos de validación y controles de acceso que permitan trazabilidad y reproducibilidad (Ali, 2024).

3. Formación integrada en finanzas y analítica.

Los hallazgos de las entrevistas a empresarios (Anexo 4) muestran brechas en la interpretación de indicadores y en el uso operativo de resultados analíticos. Por ello, los programas de capacitación deben combinar contenidos de gestión financiera práctica (p. ej., manejo de flujo de caja, análisis de márgenes) con alfabetización en analítica (interpretación de dashboards, nociones básicas de modelos de series de tiempo como ARIMA o Holt–Winters). Este enfoque facilita que el personal tome decisiones informadas y reduzca la dependencia de consultoría externa (González et al., 2024).

4. Promoción de una cultura organizacional orientada a datos.

Más allá de las herramientas, la sostenibilidad de la analítica exige rutinas organizacionales reuniones periódicas de revisión de KPI, tableros visibles para la toma de decisiones, metas basadas en indicadores que integren la evidencia en la operativa diaria. Tanto la literatura como las entrevistas señalan que la transformación cultural es el principal motor que diferencia iniciativas aisladas de procesos institucionalizados (Tay & Shen, 2023; Anexo 4 y Anexo 5).

5. Alianzas y acompañamiento externo orientado a la transferencia.

Dada la limitación de recursos en muchas PYMEs, es estratégico articular alianzas con universidades, centros tecnológicos, cámaras de comercio y programas públicos de apoyo que faciliten mentoría técnica, pilotos de validación y formación. Este lineamiento se alinea con las políticas nacionales de transformación digital y las recomendaciones institucionales documentadas (CONPES 3920; Ley 2069 de 2020) y encuentra respaldo en evidencia de casos analizados (Balestrini et al., 2024).

6. Evaluación continua y escalamiento basado en evidencia.

Se propone definir indicadores de impacto (por ejemplo, reducción de desviación en pronóstico de ventas, mejora en días de caja, tasa de cumplimiento presupuestal) y una periodicidad de evaluación (trimestral o semestral) que permita decidir sobre el escalamiento de modelos predictivos o la ampliación de cobertura funcional. Los casos de estudio (Anexo 3)

muestran que las PYMEs que monitorean resultados y ajustan iterativamente sus herramientas alcanzan mayor madurez analítica.

Los lineamientos propuestos resultan de la convergencia entre la teoría y la práctica, ofrecen una ruta pragmática, adaptable a diferentes niveles de madurez tecnológica y financiera en PYMEs colombianas. Su implementación prioriza la generación de valor temprano, la construcción de confianza en los datos y la formación del capital humano, elementos que, en conjunto, permiten que la analítica predictiva deje de ser una aspiración para convertirse en una herramienta operativa de gestión financiera.

Referencias

Aguilar, L. J. (2019). *INTELIGENCIA DE NEGOCIOS Y ANALÍTICA DE DATOS*. Bogotá:

Alfaomega.

Ahmad, N., & Lucas, E. (2024). Harnessing Predictive Analytics for SMEs: Forecasting Market

Dynamics, Enhancing Customer Insights, and Mitigating Business Risks. Obtenido de

Researchgate: <https://doi.org/10.13140/RG.2.2.21298.52160>

Ali, N. A. (2024). *Predictive analytics for the modern enterprise: A practitioner's guide to*

designing and implementing solutions. Sebastopol: O'Reilly Media.

Al-khateeb, B. A. (2024). Business Intelligence (BI). *International Journal of Asian Business*

and Information Management, 15(1), 1-15. doi:<https://doi.org/10.4018/IJABIM.340387>

Aristizábal Guzmán, J. (2025). Modelo de predicción de default en pymes de la ciudad de

Medellín. Obtenido de [https://repository.eia.edu.co/server/api/core/bitstreams/e8f785e5-](https://repository.eia.edu.co/server/api/core/bitstreams/e8f785e5-3b86-4752-b484-c3102c3ae7f9/content#:~:text=2,de%20predicci%C3%B3n%3A%20regresi%C3%B3n%20log%C3%ADstica%2C%20Random)

[3b86-4752-b484-](https://repository.eia.edu.co/server/api/core/bitstreams/e8f785e5-3b86-4752-b484-c3102c3ae7f9/content#:~:text=2,de%20predicci%C3%B3n%3A%20regresi%C3%B3n%20log%C3%ADstica%2C%20Random)

[c3102c3ae7f9/content#:~:text=2,de%20predicci%C3%B3n%3A%20regresi%C3%B3n%](https://repository.eia.edu.co/server/api/core/bitstreams/e8f785e5-3b86-4752-b484-c3102c3ae7f9/content#:~:text=2,de%20predicci%C3%B3n%3A%20regresi%C3%B3n%20log%C3%ADstica%2C%20Random)

[20log%C3%ADstica%2C%20Random](https://repository.eia.edu.co/server/api/core/bitstreams/e8f785e5-3b86-4752-b484-c3102c3ae7f9/content#:~:text=2,de%20predicci%C3%B3n%3A%20regresi%C3%B3n%20log%C3%ADstica%2C%20Random)

Arner, D. W., Barberis, J., & Buckley, R. P. (2020). The evolution of FinTech: A new post-crisis

paradigm? *Georgetown Journal of International Law*, 47(4), 1271–1319.

- Balestrini, M., Castillo, A., Echeverry, I., Castro Blandón, C., Torrico, B., Mafla, J., . . . Guillen, D. (2024). Economía del dato para pymes: claves para impulsar los negocios en la era digital y casos de uso en Latinoamérica. doi:<https://doi.org/10.18235/0013165>
- Banco Interamericano de Desarrollo . (2023). *Transformación digital y productividad de las PYMEs en América Latina y el Caribe*. BID. Obtenido de <https://publications.iadb.org/>
- Bancolombia S.A. (2024). *Informe de gestión 2023*. Medellín, Colombia: Bancolombia S.A.
- Bowen, G. A. (2009). Document analysis as a qualitative research method. *Qualitative Research Journal*, 27-40.
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77-101. doi:<https://doi.org/10.1191/1478088706qp063oa>
- Braunsberger, C., & Aschauer, E. (2025). Corporate Failure Prediction: A Literature Review of Altman Z-Score and Machine Learning Models Within a Technology Adoption Framework. *Journal of Risk and Financial Management*, 18(8), 465. doi:<https://doi.org/10.3390/jrfm18080465>
- Brown, D. &. (2019). The role of predictive analytics in financial management for SMEs. *Journal of Business Analytics*, 1, 23-41.
- Caez Anama, A. C. (2023). Diagnóstico financiero y análisis bursátil del Grupo Aval. *Repositorio institucional — UNAD*.

- Caicedo Ocampo, Y., & Sastoque Arjona, J. D. (2024). Estudio de la implementación de un sistema de inteligencia artificial para la optimización de la gestión de cartera de algunas PYMES del sector retail en Medellín. Universidad EIA. . Obtenido de <https://repository.eia.edu.co/entities/publication/b4b92996-217a-4ffd-9895-48d0b76ad404>
- Charmaz, K. (2014). *Constructing grounded theory* (2 ed.). SAGE Publications.
- Cheraghali, H., & Molnár, P. (2024). Practical insights into predicting defaults in small and medium-sized enterprises (SMEs). *Journal of the International Council for Small Business*, 1-12. doi:<https://doi.org/10.1080/26437015.2024.2430573>
- Colombia Forbes. (2023). Obtenido de Cómo Bancolombia usa la inteligencia artificial para mejorar la experiencia del cliente: <https://forbes.co>
- Confecámaras. (2023). La supervivencia empresarial en Colombia: estudio de los factores clave que impulsan la permanencia de las empresas en el mercado. Obtenido de <https://incp.org.co/wp-content/uploads/2023/05/Informe-de-supervivencia-empresarial-Confecamaras.pdf>
- Congreso de la República de Colombia. (2012). Ley 1581 de 2012: Por la cual se dictan disposiciones generales para la protección de datos personales. *Diario Oficial*, 48587 (18 octubre). Obtenido de <https://www.funcionpublica.gov.co/>

- Correa, A. (2023). Predicting Business Bankruptcy in Colombian SMEs: A Machine Learning Approach. *Journal of International Commerce, Economics and Policy*, 14(3), 1-21.
doi:<https://doi.org/10.1142/S1793993323500278>
- Creswell, J. W., & Poth, C. N. (2018). *Qualitative inquiry and research design: Choosing among five approaches* (4 ed.). SAGE Publications.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 319–340. doi:<https://doi.org/10.2307/249008>
- Deloitte. (Noviembre 2022). *Deloitte Global Corporate Treasury Survey 2022*. Deloitte.
Obtenido de <https://www.deloitte.com/content/dam/assets-zone3/us/en/docs/services/risk-advisory/2022/us-rfa-deloitte-global-treasury-survey-2022-final.pdf>
- Editorial Nubank. (2024). Unlocking the potential of sequential modeling in fraud prevention: Insights from experts at Nubank. *Unlocking the potential of sequential modeling in fraud prevention: Insights from experts at Nubank*.
- Editorial Nubank. (2025). *How Nubank models risk for smarter, scalable credit limit increases*.
- Evans, J. R. (2019). *Business analytics*. New York, NY: Pearson.
- Flick, U. (2014). *An introduction to qualitative research*. London: SAGE Publications.
- Fonseca Pinto, D. E., Fonseca Pinto, C. A., & Meo Torres, L. I. (2024). Impact of digital transformation on financial management in SMEs in Boyacá: An approach to

- competitiveness. *Journal of International Crisis and Risk Communication Research*, 7, 120-137.
- Forero, J. y. (2022). Aplicación de inteligencia artificial en el sector financiero colombiano: el caso Bancolombia. *Revista Colombiana de Innovación y Tecnología*, 45-57.
- Función Pública, D. A. (2025). *Gestor Normativo – EVA*. Obtenido de Función Pública – República de Colombia: <https://www1.funcionpublica.gov.co/web/eva/gestor-normativo>
- Gaertner, T., Lippert, C., & Konigorski, S. (2024). Automated Demand Forecasting in small to medium-sized enterprises. Obtenido de <https://arxiv.org/abs/2412.20420>
- Gallego, J. (2005). *El papel de las políticas públicas en el desarrollo de las PYMEs en Colombia*. Editorial Universidad Nacional de Colombia.
- Gee, J. P. (2014). *An introduction to discourse analysis: Theory and method* (4 ed.). Routledge.
- González Varona, J. M., López Paredes, A., Poza, D., & Acebes, F. (2024). Building and development of an organizational competence for digital transformation in SMEs. (arXiv, Ed.) doi:<https://doi.org/10.48550/arXiv.2406.01615>
- González, L. (2013). La Ley 1581 de 2012 y su impacto en las pequeñas y medianas empresas colombianas. *Derecho Digital*, 115-129.
- Hair, J. F., Hult, G. T., Ringle, C. M., & Sarstedt, M. (2021). *A primer on partial least squares structural equation modeling (PLS-SEM)*. SAGE Publications.

- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, M. d. (2014). *Metodología de la investigación*. México: McGRAW-HILL.
- Hernández, P. &. (2021). La Ley de Emprendimiento 2069 de 2020: Implicaciones y oportunidades para las PYMEs colombianas. *Revista de Derecho Empresarial*, 59-63.
- Herrera, & Casanova. (2024). Inteligencia artificial y su impacto en la transformación de la gestión financiera. *Space Scientific Journal of Multidisciplinary*, 2(1), 52-64.
- Higgins, R. C. (1977). How Much Growth Can a Firm Afford? *Financial Management*, 6(3), 7-16. doi:<https://doi.org/10.2307/3665251>
- IFRS, F. (2025). *IFRS Foundation*. Obtenido de IFRS Foundation: <https://www.ifrs.org/issued-standards/ifrs-for-smes/>
- Isaac Roque, D., Caicedo Carrero, A., & Muñoz Álvarez, A. N. (2023). Capacidad predictiva del modelo Altman Z-score en empresas declaradas en reorganización empresarial. *Apuntes de Economía y Sociedad*, 4(1), 129-141. doi:<https://doi.org/10.5377/aes.v4i1.16451>
- Kerlinger, F. N., & Lee, H. B. (1999). *Foundations of behavioral research* (3rd ed.). Harcourt College Publishers.
- Krippendorff, K. (2018). *Content analysis: An introduction to its methodology* (4 ed.). SAGE Publications.
- Kvale, S. (2007). *Doing interviews*. SAGE Publications.

Lincoln, Y. S. (1985). *Naturalistic inquiry*. Newbury Park, CA: SAGE Publications.

Liu, S., Liu, O., & Chen, J. (2023). A review on business analytics: Definitions, techniques, applications and challenges. *Mathematics*, 11(4), 899.
doi:<https://doi.org/10.3390/math11040899>

Liu, S., Liu, O., & Chen, J. (2023). A Review on Business Analytics: Definitions, Techniques, Applications and Challenges. *Mathematics*, 11(4).
doi:<https://doi.org/10.3390/math11040899>

Lontchi, C. B., Yang, B., & Shuaib, K. M. (2023). Effect of financial technology on SMEs performance in Cameroon amid COVID-19 recovery: The mediating effect of financial literacy. *Sustainability*, 15(3), 2171. doi:<https://doi.org/10.3390/su15032171>

López Henao, J., & Pinto Romero, N. A. (2023). *La receta digital de Rappi*. Medellín, Colombia: Corporación Universitaria Remington.

Ludeña, J. A. (12 de septiembre de 2021). Riesgo financiero. Obtenido de <https://economipedia.com/definiciones/riesgo-financiero.html>

Mendoza, Salazar, Constante, Cesme, Holguín, & Cruz, S. (2025). Decisiones gerenciales automatizadas: Integrando Big Data y Machine Learning. *Ciencia y Desarrollo*, 32.

Ministerio de Comercio, Industria y Turismo. (2025). *Informe de tejido empresarial*. Bogotá: Oficina Estudios Económicos. Obtenido de <https://www.mincit.gov.co/getattachment/estudios-economicos/estadisticas-e->

informes/informes-de-tejido-empresarial/2025/junio/oe-dv-informe-de-tejido-empresarial-junio-2025.pdf.aspx

Ministerio de Comercio, Industria y Turismo. (2025). *MinCIT*. Obtenido de MinCIT:
<https://www.mincit.gov.co/>

Moreno Ruiz, C. E. (2024). Funcionamiento de la plataforma Rappi dentro del ordenamiento legal colombiano desde una perspectiva del pluralismo jurídico. *Revista Doctrina Distrital*.

Nam, D., Lee, J., & Lee, H. (2019). Business analytics adoption process: An innovation diffusion perspective. *International Journal of Information Management*, 49, 411–423.
 doi:<https://doi.org/10.1016/j.ijinfomgt.2019.07.017>

Nam, D., Lee, J., & Lee, H. (2019). Business analytics adoption process: An innovation diffusion perspective. *International Journal of Information Management*, 49, 411–423.
 doi:<https://doi.org/10.1016/j.ijinfomgt.2019.07.017>

Neuendorf, K. A. (2017). *The content analysis guidebook* (2nd ed. ed.). SAGE Publications.

Noriega, J. P. (2023). Machine Learning for Credit Risk Prediction: A Systematic Literature Review. *Data*, 169.

Okeke, N. I., Bakare, O. A., & Achumie, G. O. (2024). Artificial intelligence in SME financial decision-making: Tools for enhancing efficiency and profitability. *Research Journal of*

Multidisciplinary Studies, 8(1), 150-163.

doi:<https://doi.org/10.53022/oarjms.2024.8.1.0056>

Okwaraocha, F. C., Atakora, D. A., & Morenikeji, A. W. (2024). Role of artificial intelligence and machine learning in financial modeling platforms for SMEs and financial institutions.

International Journal of Artificial Intelligence in Business, 2(2), 26-39.

doi:https://doi.org/10.34218/IJAIB_02_02_002

Osorio Gallego, C. A., Londoño Metaute, J. H., & López Zapata, E. (2016). Analysis of factors that influence the ICT adoption by SMEs in Colombia. *Intangible Capital*, 12(2), 666–732. doi:<https://doi.org/10.3926/ic.726>

Otálvaro, L. M. (2023). Adopción de Tecnologías de Inteligencia Artificial: un estudio para las empresas en Colombia.

Palomino Mantilla, M. C., & Torres Cano, E. S. (2024). *Estudio de vigilancia tecnológica aplicada a las TIC enfocadas en mejorar la eficiencia, competitividad y adaptabilidad en las PYMES de Colombia*. Trabajo de grado ,Maestría en Gerencia de Negocios–MBA, Universidad Industrial de Santander, Bucaramanga.

Pérez, J. &. (2012). *Normas Internacionales de Información Financiera: Aplicación en las PYMES colombianas*. Editorial Universidad de los Andes.

Rehman, S. U., Al-Shaikh, M., Washington, P. B., Lee, E., Song, Z., Abu-AlSondos, I. A., . . . Allahham, M. (2023). FinTech adoption in SMEs and bank credit supplies: A study on

manufacturing SMEs. *Economies*, 11(8), 213.

doi:<https://doi.org/10.3390/economies11080213>

Rodríguez, M. y. (2018). Transformación digital en PYMEs: Retos y oportunidades. *Journal of Innovation & Technology*, 81-95.

Rubio, L. (2022). Forecasting Selected Colombian Shares Using a Hybrid ARIMA–SVR Model (incluye análisis de empresas colombianas). *Mathematics (MDPI)*.

Saldaña, J. (2021). *The coding manual for qualitative researchers* (4th ed. ed.). SAGE Publications.

Settlements., B. f. (2020). Basilea III y su impacto en la gestión del riesgo en empresas pequeñas y medianas. *Journal of Risk Management*, 112-124.

Settlements., B. f. (2025). *Bank for International Settlements*. Obtenido de Bank for International Settlements: https://www.bis.org/bcbs/index.htm?utm_source=

Socarrás Molina, L. (2024). Inteligencia Artificial para la Toma de Decisiones en PYMES colombianas: Innovación Estratégica y Desarrollo Regional. 23, 2, 101–115. Revista Télématique. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=10307753>

Steri, M. F. (2022). Impulsar la banca hacia un modelo invisible. *Repositorio institucional — Universidad de los Andes*.

Strauss, A. &. (1998). *Basics of qualitative research: Techniques and procedures for developing grounded theory*. Thousand Oaks, CA: SAGE Publications.

Taborda Blandón, G. E., Castaño Zuluaga, B. S., Durán Vásquez, J. M., Conto López, R., & Reyes Moreno, E. R. (2024). Propuesta de modelo de analítica para flujo de caja en mipymes en Colombia. 22, e2607, 10. Revista CEA.
doi:<https://doi.org/10.22430/24223182.2607>

Tawil, A.-R., Mohamed, M., Schmoor, X., Vlachos, K., & Haidar, D. (2024). Trends and challenges towards effective data-driven decision making in UK small and medium-sized enterprises: Case studies and lessons learnt from the analysis of 85 SMEs. *Big Data and Cognitive Computing*, 8(7), 79. doi:<https://doi.org/10.3390/bdcc8070079>

Tay, W., & Shen, L. (2023). Predictive accuracy of Altman Z-score models across industries. *Journal of Risk and Financial Management*, 16(8), 465.
doi:https://doi.org/10.3390/jrfm16080465?utm_source=

Tobón Perilla, L. N., Urquía Grande, E., & Cano Montero, E. I. (2022). The use of financial information in the business management of SMEs in Colombia. *Revista Perspectiva Empresarial*, 9(2), 11-23. doi:<https://doi.org/10.16967/23898186.791>

Tornatzky, L. G., & Fleischer, M. (1990). *The processes of technological innovation*. Lexington Books.

- Torres Vargas, G. E. (2025). *Desafíos y oportunidades en la integración tecnológica y liderazgo para la gerencia Fintech: Caso de Addi Colombia*. Bogotá: Repositorio institucional – Universidad EAN.
- Utama, I. D., Karmagatri, M., Kurnianingrum, D., & Yustian, O. R. (2022). Analysis of SMEs consideration in adopting new technology using Technology Acceptance Model. En IEEE (Ed.), *International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*.
doi:<https://doi.org/10.1109/ICIMCIS56303.2022.10017790>
- Valarezo Avila, B., Córdova Aponte, M., & Serrano Orellana, B. (2021). Inteligencia de negocios como herramienta clave en el desempeño empresarial. *593 Digital Publisher CEIT*, 6(6), 306-325. doi:<https://doi.org/10.33386/593dp.2021.6.727>
- Vargas, L. (2017). Resistencia a la digitalización en PYMEs colombianas: Un estudio cultural y organizacional. *Journal of Management and Innovation*, 49-61.
- Wasserbacher, H., & Spindler, M. (2021). *Machine learning for financial forecasting, planning and analysis: Recent developments and pitfalls*. Obtenido de arXiv:
<https://arxiv.org/abs/2107.04851>
- Wasserbacher, H., & Spindler, M. (2022). Machine learning for financial forecasting, planning and analysis: Recent developments and pitfalls. *Digital Finance*, 4(1), 63-68.
doi:[10.1007/s42521-021-00046-2](https://doi.org/10.1007/s42521-021-00046-2)

Westreicher, G. (26 de abril de 2020). Gestión Financiera: Qué es y cómo optimiza los recursos.

Obtenido de <https://economipedia.com/definiciones/gestion-financiera.html>

Anexos

Anexo 1

Formato de Matriz Documental

Objetivo: Organizar y sintetizar la información relevante proveniente de fuentes secundarias que contribuyan al análisis teórico del estudio.

Tabla 7.

Formato de Matriz Documental

Elemento de análisis	Descripción
Autor	Identifica el o los autores y el año de publicación del documento o estudio analizado.
Año	
Título del estudio o documento	Registra el nombre completo de la publicación o informe revisado.
Fuente	Señala el país, institución o entidad que publica el documento, así como el contexto de aplicación.
País de estudio	
Contexto	
Tipo de documento	Indica el enfoque o método utilizado en el estudio (cualitativo, cuantitativo, mixto, normativo, etc.).
Principales hallazgos o aportes	Resume los resultados o conclusiones relevantes que aportan al marco conceptual de la investigación.
Relevancia para el estudio	Explica la conexión entre el documento y los objetivos específicos del presente proyecto.

Anexo 2

Guía de Entrevista Semiestructurada

Objetivo: Explorar el nivel de conocimiento, adopción y percepción sobre las herramientas de *machine learning* en la gestión financiera de PYMEs colombianas.

Preguntas guía:

1. ¿Podría describir brevemente su rol dentro de la empresa y las principales decisiones financieras que toma?
2. ¿Ha escuchado o utilizado herramientas basadas en *machine learning* o analítica de datos en su empresa? Si es así, ¿para qué propósito?
3. ¿Qué factores considera que facilitan o dificultan la adopción de este tipo de tecnologías en las PYMEs?
4. ¿Qué beneficios percibe o cree que podrían obtenerse al implementar herramientas analíticas en la gestión financiera?
5. ¿Qué limitaciones, riesgos o barreras ha identificado en su experiencia o en su entorno empresarial respecto al uso de *machine learning*?
6. ¿Qué tipo de apoyo (institucional, financiero o formativo) considera necesario para fomentar la adopción de estas herramientas en PYMEs?
7. ¿Cómo visualiza el papel de la analítica y el *machine learning* en el futuro de la gestión empresarial de su organización?

Preguntas guía expertos en Machine Learning:

1. Desde su experiencia, ¿cuáles son los factores técnicos y organizacionales que determinan la adopción o resistencia de ML en PYMEs?
2. ¿Qué modelos o técnicas considera más viables para predicción financiera en PYMEs?
3. ¿Cómo recomienda integrar modelos predictivos dentro de tableros BI para aportar valor operativo?
4. ¿Qué métricas o métodos sugiere para validar un modelo en contexto PYME?
5. ¿Qué prácticas de gobernanza y ética recomienda implementar en proyectos de ML?
6. ¿Podría mencionar un caso exitoso donde ML haya generado impacto en finanzas de PYMEs o empresas similares?
7. ¿Qué arquitectura o herramientas recomendaría para comenzar en una PYME con recursos limitados?
8. ¿Qué pasos concretos debería seguir una PYME en los próximos 6 meses para avanzar en inteligencia financiera con analítica predictiva?
9. ¿Podría recomendar lecturas, recursos o casos útiles para esta investigación?
10. ¿Desea agregar algún comentario final o recomendación adicional?

Anexo 3
Casos de Estudio

Caso 1: Implementación de Machine Learning en el Centro de Competencias de Inteligencia Artificial de Bancolombia

Tabla 8.
Implementación de Machine Learning en el Centro de Competencias de Inteligencia Artificial de Bancolombia

Elemento de análisis	Descripción
Autor	Bancolombia.
Año	2024
Título del estudio o documento	Implementación de Machine Learning en el Centro de Competencias de Inteligencia Artificial de Bancolombia
Fuente	Informe de Gestión 2023
País de estudio	Colombia
Contexto	Bancolombia ha integrado el uso de Machine Learning como parte de su estrategia de transformación digital, con el fin de optimizar procesos internos y mejorar la experiencia de sus clientes. A través de su Centro de Competencias de Inteligencia Artificial, la entidad ha desarrollado modelos predictivos que permiten anticipar comportamientos de los usuarios, detectar posibles fraudes y personalizar productos financieros según las necesidades de cada cliente. Esta adopción tecnológica ha permitido automatizar tareas que antes requerían intervención manual, mejorar la eficiencia operativa y fortalecer la toma de decisiones basada en datos. Gracias a estas iniciativas, Bancolombia se ha consolidado como una de las entidades pioneras en la aplicación de inteligencia artificial en el sector financiero de América Latina
Tipo de documento	Informe corporativo / reporte anual de empresa.
Principales hallazgos o aportes	La implementación de Machine Learning en Bancolombia ha generado avances significativos tanto en la eficiencia operativa como en la calidad del servicio al cliente. Entre los principales aportes se destaca la capacidad de los modelos predictivos para anticipar necesidades financieras, lo que permite ofrecer productos personalizados y fortalecer la fidelización de los usuarios. Además, los algoritmos de detección de fraude han mejorado notablemente la seguridad de las transacciones, reduciendo pérdidas y tiempos de respuesta ante eventos

	sospechosos. En el ámbito interno, el uso de analítica avanzada ha optimizado procesos de crédito, cobranza y gestión de riesgo, contribuyendo a una toma de decisiones más ágil y basada en datos reales. Estos resultados evidencian cómo el uso estratégico del Machine Learning potencia la competitividad y la innovación en el sector bancario colombiano
Relevancia para el estudio	El caso de Bancolombia resulta altamente relevante para el estudio del uso de Machine Learning en empresas PYMES, especialmente en el ámbito del análisis financiero. Aunque se trata de una gran entidad, su experiencia demuestra cómo la adopción de modelos predictivos, análisis automatizado de riesgos y personalización de servicios financieros puede aplicarse a organizaciones de menor escala. Bancolombia ha evidenciado que el machine Learning permite mejorar la precisión en la evaluación crediticia, anticipar riesgos financieros y optimizar decisiones de inversión, aspectos que son igualmente críticos para las PYMES. Este caso sirve como referencia de buenas prácticas y muestra el potencial de la inteligencia artificial para transformar la gestión financiera en distintos niveles empresariales, desde grandes corporaciones hasta pequeñas y medianas empresas

Caso 2: Aplicación de Machine Learning y Analítica Avanzada en el Ecosistema de Rappi para la Personalización y Escalabilidad

Tabla 9.

Aplicación de Machine Learning y Analítica Avanzada en el Ecosistema de Rappi para la Personalización y Escalabilidad

Elemento de análisis	Descripción
Autor	López Henao, J. & Pinto Romero, N. A,
Año	2024
Título del estudio o documento	Funcionamiento de la plataforma Rappi dentro del ordenamiento legal colombiano desde una perspectiva del pluralismo jurídico.
Fuente	Revista Académica
País de estudio	Colombia
Contexto	Rappi, plataforma tecnológica latinoamericana de origen colombiano que opera en múltiples servicios (pedidos de comida, supermercado, fintech, etc.), ha integrado analítica avanzada y elementos de <i>machine learning</i> en su operación para optimizar la experiencia del usuario, personalizar ofertas, fomentar la reactivación de clientes inactivos y escalar su crecimiento. Por ejemplo, enfrentaba el reto de “recuperar clientes inactivos mediante experiencias personalizadas” y lo resolvió mediante campañas apoyadas por datos que incrementaron el valor de vida del cliente y el retorno de la inversión
Tipo de documento	Artículo Académico
Principales hallazgos o aportes	La implementación de machine learning en Rappi ha permitido fortalecer su modelo de negocio a través de la personalización avanzada y la optimización operativa. Uno de los principales aportes ha sido el desarrollo de sistemas de recomendación que analizan en tiempo real los hábitos de consumo de los usuarios, sugiriendo productos o servicios con alta probabilidad de conversión. Además, Rappi utiliza modelos predictivos para anticipar la demanda y optimizar la asignación de repartidores, reduciendo tiempos de entrega y mejorando la satisfacción del cliente. Estas aplicaciones han incrementado la retención de usuarios y el valor de vida del cliente (Customer Lifetime Value), demostrando que el uso de analítica avanzada puede generar ventajas competitivas sostenibles

Relevancia para el estudio	El caso de Rappi es especialmente relevante para el análisis del uso de machine learning en PYMES enfocadas en el análisis financiero, ya que evidencia cómo la aplicación de algoritmos de predicción y segmentación puede mejorar la rentabilidad y la eficiencia de los recursos. Aunque Rappi es una empresa tecnológica de gran escala, muchas de sus estrategias —como la predicción de demanda, la evaluación de patrones de consumo y la personalización de ofertas— pueden ser adaptadas por PYMES para optimizar su flujo de caja y estrategias de ventas. El enfoque de Rappi demuestra que la integración del machine learning no solo impulsa la toma de decisiones basada en datos, sino que también contribuye a una gestión financiera más precisa y orientada al comportamiento del cliente
----------------------------	---

Caso 3: Implementación de Machine Learning en Nubank para la Optimización del Riesgo Crediticio y la Personalización Financiera

Tabla 10.

Implementación de Machine Learning en Nubank para la Optimización del Riesgo Crediticio y la Personalización Financiera

Elemento de análisis	Descripción
Autor	Noriega, J. P., Rivera, L. A., & Herrera, J. A.
Año	2023
Título del estudio o documento	Machine Learning for Credit Risk Prediction: A Systematic Literature Review.
Fuente	Revista Data
País de estudio	Perú
Contexto	Nubank, uno de los neobancos más grandes del mundo y líder en América Latina, ha incorporado el machine learning como elemento central de su modelo de negocio para transformar la manera en que ofrece servicios financieros. Desde su creación, la empresa ha desarrollado sistemas automatizados que analizan grandes volúmenes de datos de clientes para evaluar riesgos crediticios, detectar fraudes y personalizar productos financieros. Estos modelos permiten decisiones más precisas y rápidas, facilitando el acceso a crédito incluso a usuarios sin historial bancario. Además, Nubank emplea algoritmos de aprendizaje automático para mejorar la atención al cliente mediante chatbots inteligentes y análisis de comportamiento financiero, fortaleciendo así la inclusión y confianza digital
Tipo de documento	Artículo de revista científica
Principales hallazgos o aportes	La implementación de machine learning en Nubank ha generado resultados notables en la eficiencia operativa, la toma de decisiones y la experiencia del cliente. Uno de los principales aportes es el desarrollo de modelos de riesgo crediticio basados en datos alternativos, que permiten otorgar crédito a personas previamente excluidas del sistema financiero tradicional. Además, la automatización mediante algoritmos ha reducido los tiempos de aprobación de productos financieros y mejorado la detección de fraudes en transacciones. Otro hallazgo relevante es la personalización dinámica de las ofertas, lograda gracias al análisis predictivo del comportamiento financiero de los usuarios. En conjunto, estas estrategias han fortalecido la fidelización, ampliado la inclusión financiera y posicionado a

	Nubank como referente en la aplicación ética y eficiente del machine learning en la banca digital
Relevancia para el estudio	El caso de Nubank resulta especialmente relevante para el análisis del machine learning en PYMES enfocadas en el ámbito financiero, ya que evidencia cómo los modelos predictivos pueden transformar la gestión del riesgo y la toma de decisiones basada en datos. Aunque Nubank opera a gran escala, su enfoque en evaluar el comportamiento financiero de clientes mediante datos no tradicionales como hábitos de pago, patrones de consumo o interacciones digitales puede inspirar a las PYMES a desarrollar soluciones de análisis adaptadas a sus propios contextos. La experiencia de Nubank demuestra que el machine learning puede emplearse para mejorar la precisión en la evaluación crediticia, optimizar flujos de caja y personalizar estrategias financieras, contribuyendo así a una administración más inteligente y sostenible de los recursos empresariales

Caso 4: Transformación mediante Machine Learning en Grupo Aval para mejora de procesos y gestión de riesgos

Tabla 11.

Transformación mediante Machine Learning en Grupo Aval para mejora de procesos y gestión de riesgos

Elemento de análisis	Descripción
Autor	Caez Anama, A. C.
Año	2023
Título del estudio o documento	Diagnóstico financiero y análisis bursátil del Grupo Aval
Fuente	Repositorio institucional — UNADC
País de estudio	Colombia
Contexto	Grupo Aval, uno de los conglomerados financieros más grandes de Colombia, ha emprendido una estrategia de transformación digital que incorpora el uso de <i>machine learning</i> y analítica avanzada en varias de sus entidades. Por medio de su centro de innovación ADL Digital Lab, el grupo ha desarrollado modelos predictivos para la asignación de créditos, detección de fraude, personalización de productos, automatización de procesos internos y análisis de clientes con comportamientos emergentes. Esta iniciativa forma parte de su alianza estratégica con Microsoft para impulsar IA e infraestructura en la nube, con el objetivo de mejorar la eficiencia operativa, la experiencia del cliente y la gestión prudente del riesgo.
Tipo de documento	Trabajo académico / informe
Principales hallazgos o aportes	La implementación de machine learning en Grupo Aval ha permitido mejorar significativamente la eficiencia operativa y la gestión del riesgo dentro del conglomerado financiero. A través de modelos predictivos avanzados, la entidad ha optimizado los procesos de aprobación de créditos, reduciendo tiempos y costos, al tiempo que incrementa la precisión en la evaluación del comportamiento de los clientes. Del mismo modo, el uso de algoritmos de inteligencia artificial ha fortalecido los sistemas de detección de fraude, permitiendo una respuesta más oportuna ante operaciones sospechosas y mejorando la resiliencia de sus plataformas digitales. Además, la alianza estratégica con Microsoft ha impulsado el desarrollo de soluciones basadas en IA generativa y herramientas low-code/no-code, que facilitan la creación y despliegue de nuevos modelos de análisis en sus diferentes entidades financieras.

Otro de los aportes más relevantes ha sido la consolidación de una cultura organizacional orientada al uso de datos, promoviendo la capacitación de su talento humano en analítica y ciencia de datos, y fomentando la innovación tecnológica como eje estratégico. Esta evolución ha permitido que Grupo Aval no solo mejore la personalización de productos y servicios financieros, sino que también amplíe el alcance de sus soluciones de IA hacia otras filiales, aprovechando la infraestructura en la nube para replicar modelos escalables en toda la región. En conjunto, estos avances han posicionado al grupo como un referente en la adopción responsable y efectiva del machine learning dentro del sistema financiero colombiano

Relevancia para el
estudio

Caso 5: Addi: Crédito instantáneo y evaluación automatizada mediante Machine Learning en el sector fintech colombiano

Tabla 12.

Addi: Crédito instantáneo y evaluación automatizada mediante Machine Learning en el sector fintech colombiano

Elemento de análisis	Descripción
Autor	Torres Vargas, G. E.
Año	2025
Título del estudio o documento	Desafíos y oportunidades en la integración tecnológica y liderazgo para la gerencia Fintech: Caso de Addi Colombia
Fuente	Repositorio institucional – Universidad EAN
País de estudio	Colombia
Contexto	Addi es una empresa fintech fundada en Colombia en 2018, cuyo modelo de negocio se basa en el uso de machine learning y analítica avanzada para ofrecer créditos de consumo de manera ágil, segura y personalizada. A través de sus modelos predictivos, la compañía analiza miles de variables — incluyendo comportamiento de compra, historial digital y datos no tradicionales— para determinar la viabilidad crediticia de los usuarios en cuestión de segundos. Este enfoque le ha permitido competir con bancos tradicionales y posicionarse como un referente regional en soluciones de pago y crédito “Compra ahora, paga después” (<i>Buy Now, Pay Later</i>). Addi utiliza infraestructuras en la nube y modelos de IA supervisados y no supervisados para optimizar la asignación de riesgo, mejorar la detección de fraude y ampliar la inclusión financiera en mercados como Colombia, Brasil y México
Tipo de documento	Trabajo de grado (maestría)
Principales hallazgos o aportes	La implementación de machine learning en Addi ha transformado la forma en que se otorgan y gestionan los créditos de consumo en América Latina. A través de modelos predictivos basados en datos de comportamiento y fuentes alternativas, la empresa logra evaluar el riesgo crediticio de los usuarios en segundos, reduciendo drásticamente los tiempos de aprobación y los costos operativos. Este enfoque ha permitido mejorar la precisión en la identificación de clientes solventes y disminuir los niveles de morosidad. Asimismo, la compañía ha desarrollado sistemas automáticos de detección de fraude y modelos de segmentación de clientes que optimizan las tasas de conversión y personalizan la oferta de productos. La integración

	de machine learning con plataformas de pago digital también ha potenciado su propuesta <i>Buy Now, Pay Later</i> (BNPL), generando mayor acceso al crédito y fomentando la inclusión financiera en sectores tradicionalmente desatendidos
Relevancia para el estudio	El caso de Addi resulta altamente relevante para el estudio del uso de machine learning en PYMES, especialmente dentro del ámbito financiero, porque demuestra cómo una empresa de origen colombiano ha logrado escalar su modelo de negocio apoyándose casi exclusivamente en el análisis automatizado de datos. Addi nació como un startup con recursos limitados y un enfoque innovador en la digitalización del crédito, lo que la convierte en un referente de cómo las pequeñas y medianas empresas pueden adoptar la inteligencia artificial sin requerir una infraestructura bancaria tradicional. Su éxito evidencia que los algoritmos de machine learning pueden aplicarse no solo a la gestión del riesgo crediticio, sino también a la optimización de la cartera, la segmentación de clientes y la personalización de estrategias financieras. Además, la experiencia de Addi muestra cómo el aprovechamiento de datos alternativos como el historial de compras, comportamiento en línea y variables sociodemográficas puede mejorar la precisión de los modelos predictivos y abrir nuevas oportunidades de inclusión financiera en mercados emergentes. Para las PYMES, este enfoque representa una vía viable para fortalecer su análisis financiero, anticipar tendencias y gestionar de forma más eficiente los recursos. En conjunto, Addi se posiciona como un ejemplo concreto de cómo la implementación estratégica de machine learning puede incrementar la competitividad, sostenibilidad e innovación dentro del ecosistema financiero latinoamericano

Caso 6: Economía del Dato para Pymes: Claves para Impulsar los Negocios en la Era Digital y Casos de Uso en Latinoamérica

Tabla 13.

Economía del Dato para Pymes: Claves para Impulsar los Negocios en la Era Digital y Casos de Uso en Latinoamérica

Elemento de análisis	Descripción
Autor	Balestrini, M., Castillo, A., Echeverry, I., Castro Blandón, C., Torrico, B., Mafla, J., Guzmán, M., Di Giovanni, L., Rojas, D., & Guillen, D.
Año	2024
Título del estudio o documento	Economía del dato para pymes: claves para impulsar los negocios en la era digital y casos de uso en Latinoamérica
Fuente	Banco Interamericano de Desarrollo.
País de estudio	Colombia, Uruguay, El Salvador.
Contexto	Este informe explora cómo la economía del dato se ha vuelto un habilitador esencial para que las PYMEs en America Latina enfrenten los desafíos empresariales actuales, destacando la adopción de soluciones de análisis de datos para tomar decisiones más ágiles y estratégicas, incluyendo casos de uso de PYMEs que, tras implementar herramientas de analítica de datos, lograron resultados positivos en sus negocios.
Tipo de documento	Informe técnico institucional.
Principales hallazgos o aportes	Uno de los hallazgos más importantes es que la mayoría de las PYMEs en América Latina todavía están en etapas iniciales de transformación digital, y aún más rezagadas en el uso de datos para tomar decisiones. No obstante, el documento demuestra que esto no es una limitante definitiva, porque existen herramientas de fácil acceso y gratuitas que ayudan a la implementación de Machine Learning. Por ejemplo, empresas como Brenson SAS (de Colombia) mostraron cómo implementar tableros de control, análisis de indicadores y automatización de reportes puede traducirse en decisiones más rápidas, mejores pronósticos y un uso más estratégico de los recursos. El informe también destaca que el análisis de datos no solo es útil para lo financiero, sino también para entender mejor al

cliente, optimizar operaciones, predecir la demanda o incluso diseñar productos personalizados.

Otro aporte es el Toolkit que se propone en el documento, donde se detallan fases prácticas para que una PYME empiece a trabajar con datos, identificando las fuentes de información internas, trabajar en una gobernanza de datos, hasta construir modelos simples de predicción con herramientas como Excel o Power BI.

Finalmente se resalta tecnologías como lo son: Power bi, Excel, Tableau, CRM, Google Sheets, ERP, y para gestión de proyectos: Trello y Asana.

Relevancia para el estudio

El informe ayuda a entender las limitaciones que enfrentan las PYMEs en la gestión de datos. Este muestra cómo las PYMEs aún no saben cómo empezar a usar sus propios datos, lo que refuerza la necesidad de diseñar estrategias simples y accesibles para avanzar.

Adicional, se ilustran casos reales de implementación de herramientas de analítica en PYMEs, como dashboards, predicción de demanda, visualización de indicadores financieros y automatización de reportes. Aunque no todos los casos utilizan machine learning avanzado, sí demuestran cómo estas herramientas permiten anticipar decisiones financieras clave como inversiones, ajustes de inventario o estrategias de crecimiento.

Caso 7: Propuesta de Modelo de Analítica para Flujo de Caja en MIPYMES en Colombia.

Tabla 14.

Propuesta de Modelo de Analítica para Flujo de Caja en MIPYMES en Colombia.

Elemento de análisis	Descripción
Autor	Taborda Blandón, G. E., Castaño Zuluaga, B. S., Durán Vásquez, J. M., Conto López, R., y Reyes Moreno, E. R.
Año	2024
Título del estudio o documento	Propuesta de modelo de analítica para flujo de caja en mipymes en Colombia.
Fuente	Revista CEA. Instituto Tecnológico Metropolitano (Medellín.)
País de estudio	Colombia.
Contexto	Este estudio propone un modelo de analítica de datos para el monitoreo del flujo de caja de las MiPYMES, con el fin de apoyar su sostenimiento financiero. Mediante una encuesta y revisión del estado del arte, los autores caracterizaron cómo las PYMEs colombianas gestionan su flujo de caja, encontrando que pocas PYMEs llevan un control adecuado de flujo de caja, lo cual es preocupante dada la baja tasa de supervivencia empresarial. El equipo desarrolló y evaluó varios modelos predictivos aplicados a datos de flujo de caja; en particular, el modelo de Random Forest resultó ser el más eficaz con una precisión del 76,7%, una sensibilidad del 83,3% y una especificidad del 70%.
Tipo de documento	Artículo de revista académica.
Principales hallazgos o aportes	Se evidencia que la mayoría de las PYMES no usa herramientas tecnológicas para proyectar su flujo de efectivo, y que muchas decisiones financieras se toman con base en la intuición o la urgencia, sin un análisis previo. A través de un modelo de analítica predictiva aplicado (random forest) se logró demostrar este modelo fue efectivo para predecir situaciones de iliquidez, alcanzando una precisión superior al 76% y una sensibilidad de más del 83%, lo que significa que puede anticipar de forma confiable cuándo una empresa podría quedarse sin caja. Otro hallazgo clave es que los autores proponen una herramienta visual tipo dashboard, que permite simular

	diferentes escenarios y hacer proyecciones en lenguaje claro para los empresarios, sin necesidad de conocimientos técnicos avanzados.
Relevancia para el estudio	Este documento se alinea con los objetivos específicos propuestos, especialmente en lo relacionado con la aplicación práctica de modelos predictivos para apoyar la gestión financiera de las PYMEs aportando evidencia concreta de que es posible implementar modelos como Random Forest en un entorno empresarial a bajo costo, reforzando igualmente que el uso de dashboards y herramientas visuales de Business Intelligence facilita la toma de decisiones en empresas que no tienen grandes capacidades técnicas.

Caso 8: Modelo de Predicción de Default en PYMEs de la Ciudad de Medellín.

Tabla 15.

Modelo de Predicción de Default en PYMEs de la Ciudad de Medellín.

Elemento de análisis	Descripción
Autor	Aristizábal Guzmán, J.
Año	2025
Título del estudio o documento	Modelo de predicción de default en PYMEs de la ciudad de Medellín.
Fuente	Universidad EIA
País de estudio	Colombia.
Contexto	Esta investigación desarrolla y compara modelos de Machine Learning para estimar el riesgo de default (incumplimiento crediticio) en PYMEs de Medellín, usando datos financieros históricos de empresas locales. Construyeron tres modelos supervisados: Regresión Logística, Random Forest y Redes Neuronales entrenados con variables financieras. Como resultados, el modelo de Random Forest sobresalió, logrando una exactitud del 96.3% y mejor equilibrio entre precisión (94,3) y sensibilidad (98,7), superando a los otros enfoques planteados. Aunque la regresión logística ofrece interpretabilidad y las redes neuronales muestran buen desempeño, el Random Forest brindó el mejor rendimiento predictivo y generalización en este contexto.
Tipo de documento	Trabajo de grado.
Principales hallazgos o aportes	Uno de los principales hallazgos es la aplicabilidad real del Machine Learning en el entorno financiero de las PYMEs en Colombia, específicamente para predecir el riesgo del incumplimiento crediticio, siendo el hallazgo más relevante el modelo Random Forest, el cual obtuvo el mejor desempeño, superando tanto a la regresión logística como a la red neuronal en términos de precisión y sensibilidad, reforzando la idea de que los modelos de ensamble no solo son robustos ante datos complejos, sino también adecuados para entornos como el de las PYMEs, donde puede haber ruido o datos incompletos.
Relevancia para el estudio	El documento aporta evidencias concretas y aplicadas sobre cómo modelos de Machine Learning pueden fortalecer la inteligencia financiera de las PYMEs. La investigación no se queda en el análisis teórico, sino que construye y prueba

modelos reales sobre datos financieros de empresas de Medellín, confirmando que modelos predictivos como Random Forest y redes neuronales son útiles para anticipar riesgos financieros como el default.

Otro punto que refuerza nuestro estudio es que el trabajo demuestra la posibilidad de usar datos históricos disponibles para generar valor estratégico, validando que incluso sin grandes recursos, una PYME puede empezar a aplicar analítica predictiva si cuenta con una estructura de datos mínima y un enfoque bien orientado.

Caso 9: Inteligencia Artificial para la Toma de Decisiones en PYMES colombianas: Innovación Estratégica y Desarrollo Regional.

Tabla 16.

Inteligencia Artificial para la Toma de Decisiones en PYMES colombianas: Innovación Estratégica y Desarrollo Regional.

Elemento de análisis	Descripción
Autor	Socarrás Molina, L.
Año	2024
Título del estudio o documento	Inteligencia artificial para la toma de decisiones en pymes colombianas: innovación estratégica y desarrollo regional.
Fuente	Universidad Rafael Belloso Chacín.
País de estudio	Colombia.
Contexto	Este estudio se desarrolla en la región de Valledupar (Colombia), donde las PYMES carecen de infraestructura tecnológica sólida, limitando la adopción de estrategias basadas en datos. Ante esto, la investigación plantea que el uso de Machine Learning puede ser una herramienta transformadora para mejorar la eficiencia operativa y la adaptabilidad de estas empresas, reduciendo la toma de decisiones basada solo en la intuición y permitiendo decisiones más informadas y estratégicas.
Tipo de documento	Artículo de investigación publicado en revista científica <i>Télématique</i> (Vol. 23, Núm. 02, 2024).
Principales hallazgos o aportes	El artículo encuentra que la incorporación de técnicas de Machine Learning en la toma de decisiones empresariales produce mejoras tangibles en las PYMES. Específicamente, aquellas empresas que adoptan IA experimentan mayor eficiencia operativa, reducción de costos y una mejor capacidad de adaptación al cambio, en donde a través de lenguajes de programación como Python en el entorno de trabajo de Google Colab que es gratuito, implementó modelos de redes neuronales y algoritmos genéticos para pronosticar patrones de consumo y optimizar la asignación de recursos. Para llegar a estos resultados, el autor recopiló datos mediante encuestas a directivos de PYMES y verificó la confiabilidad del instrumento con el coeficiente Alpha de Cronbach, concluyendo que la IA debe implementarse de una manera gradual: requiere apoyo institucional, capacitación en

	tecnologías avanzadas y adaptar los modelos algorítmicos a la realidad de las empresas.
Relevancia para el estudio	En primer lugar, el estudio aborda directamente el impacto de la IA en las decisiones estratégicas de PYMES colombianas en donde los hallazgos refuerzan la idea central del estudio: la adopción de modelos de machine learning y técnicas de IA puede fortalecer la inteligencia financiera y competitividad de las PYMES, al mejorar la precisión en pronósticos y la toma de decisiones basadas en datos. Además, la investigación proporciona evidencia empírica de beneficios concretos como lo son la eficiencia, ahorro de costos, adaptabilidad, lo cual sustenta la importancia de introducir herramientas predictivas en las pequeñas empresas.

Caso 10: Estudio de Implementación de un Sistema de Inteligencia Artificial para la Optimización de la Gestión de Cartera de Algunas PYMES del Sector Retail de Medellín

Tabla 17.

Estudio de Implementación de un Sistema de Inteligencia Artificial para la Optimización de la Gestión de Cartera de Algunas PYMES del Sector Retail de Medellín.

Elemento de análisis	Descripción
Autor	Caicedo Ocampo, Y Sastoque Arjona, J.
Año	2025
Título del estudio o documento	Estudio de implementación de un sistema de inteligencia artificial para la optimización de la gestión de cartera de algunas PYMES del sector retail de Medellín
Fuente	Universidad EIA
País de estudio	Colombia
Contexto	En Medellín muchas PYMEs enfrentan dificultades para gestionar sus cuentas por cobrar de forma eficiente, predominando procesos manuales y sistemas obsoletos que generan retrasos en los cobros, acumulación de deudas incobrables y problemas de flujo de caja, al carecer de capacidades de análisis avanzado. Ante esto, el estudio plantea que técnicas de Machine Learning y analítica avanzada surge como una solución para automatizar y agilizar la gestión de cartera, proporcionando información valiosa para decisiones estratégicas. El proyecto se enfocó en PYMEs del sector comercial y de servicios en Medellín, con ventas anuales entre 500 millones y 5.000 millones de pesos colombianos, un segmento representativo cuyas características específicas se tuvieron en cuenta en el diseño de la solución
Tipo de documento	Trabajo de grado.
Principales hallazgos o aportes	Se entrenó un modelo predictivo (Random Forest Regressor) en Python junto con librerías especializadas como pandas y scikit-learn con datos históricos de crédito (8.187 registros de operaciones de cartera) de una PYME, con los siguientes resultados: R2: 0,4932, RMSE: 72,955 (en unidades monetarias) y MAPE: 60,65%, lo que indica una capacidad predictiva moderada pero útil para el propósito. Este modelo se seleccionó debido a su robustez para capturar patrones complejos y evitar sobreajuste en conjuntos de datos pequeños.

La implementación del sistema de IA mostró mejoras significativas en la gestión de la cartera de las PYMEs analizadas. En términos prácticos, el modelo permitió incrementar la eficiencia operativa, al priorizar mejor las cobranzas y automatizar alertas de pago, reducir la morosidad y aumentar la rentabilidad financiera de esas empresas.

De acuerdo al estudio, se identificaron las variables más influyentes para predecir la probabilidad de recuperación de la cartera, revelando que el valor de la factura y el saldo pendiente son de los factores con mayor peso. Asimismo, los días de mora y el hecho de que una factura esté castigada o dada por perdida resultaron ser críticos para anticipar si una cuenta se volverá incobrable, indicando cuándo se requieren acciones correctivas urgentes. Otro factor importante fue la proporción de descuento ofrecido en la factura, que mide el incentivo comercial para pagar pronto.

Mediante una simulación de Monte Carlo a 36 meses y 1000 escenarios, calcularon el Retorno sobre la Inversión (ROI) esperado al implementar el sistema, obteniendo los siguientes resultados: en promedio, el ROI salió positivo, cercano al 51%, lo que implica que, si la iniciativa es rentable, la empresa recuperaría aproximadamente 1,51 veces lo invertido en el sistema. Incluso en escenarios conservadores el ROI mediano rondó el 93% y en ninguno de los casos simulados resultó negativo demostrando que, bajo múltiples condiciones económicas, la herramienta aporta valor y prácticamente asegura beneficios netos para la empresa usuaria, es decir, invertir en este sistema de IA vale la pena para la PYME, ya que mejora la recuperación de cartera y paga con creces su costo.

Finalmente, los autores señalaron que la calidad y disponibilidad de los datos financieros es un factor crítico, si la información histórica de la empresa es incompleta o poco confiable, el modelo tendrá limitaciones, recomendando en invertir en mejorar la captura y limpieza de datos antes y durante la adopción de la IA.

Relevancia para el estudio

Este estudio demuestra que la adopción estratégica de soluciones de IA efectivamente puede mejorar la sostenibilidad financiera y competitividad de las PYMEs, al lograr mayor eficiencia operativa y reducir el riesgo de cartera morosa, evidenciando que un modelo de Machine Learning

bien implementado tradujo datos históricos en acciones de negocio más informadas, con impacto positivo en indicadores financieros reales.

Caso 11: Adopción de Tecnologías Financieras y Alfabetización Financiera como Factores del Desempeño de las PYMEs Camerunesas.

Tabla 18.

Adopción de Tecnologías Financieras y Alfabetización Financiera como Factores del Desempeño de las PYMEs Camerunesas

Elemento de análisis	Descripción
Autor	Lontchi, C. B., Yang, B., & Shuaib, K. M.
Año	2023
Título del estudio o documento	Effect of Financial Technology on SMEs Performance in Cameroon amid COVID-19 Recovery: The Mediating Effect of Financial Literacy.
Fuente	Sustainability (MDPI).
País de estudio	Camerún.
Contexto	El estudio analiza cómo las tecnologías financieras (FinTech) influyen en el desempeño de las PYMEs en Camerún después de la pandemia de COVID-19. Se destaca la importancia de la alfabetización financiera como mediadora en el impacto de las herramientas tecnológicas sobre el rendimiento de las empresas.
Tipo de documento	Artículo científico
Principales hallazgos o aportes	El estudio realizado por Lontchi, Yang y Shuaib (2023) evidenció que la adopción de tecnologías financieras (FinTech) tiene un impacto positivo y estadísticamente significativo en el desempeño de las pequeñas y medianas empresas (PYMEs) de Camerún, especialmente durante la etapa de recuperación económica posterior a la pandemia de COVID-19. Los autores emplearon el modelo de ecuaciones estructurales PLS-SEM para analizar la relación entre la adopción tecnológica, la alfabetización financiera y el rendimiento empresarial. Los resultados confirmaron que las empresas con mayor nivel de alfabetización financiera logran aprovechar de manera más eficiente las herramientas FinTech, mejorando aspectos clave como la liquidez, la administración del flujo de caja y la eficiencia en los pagos digitales. Los hallazgos también demostraron que la alfabetización financiera actúa como un factor mediador esencial en la relación entre la adopción de tecnología y el desempeño organizacional. En términos cuantitativos, se estimó que

aproximadamente el 64 % de la variación en el desempeño empresarial podía explicarse por la interacción entre el uso de herramientas FinTech y el nivel de conocimiento financiero. Además, las empresas que adoptaron soluciones como billeteras digitales, plataformas de banca en línea y sistemas de crédito automatizado reportaron una reducción del 27 % en los retrasos de pago a proveedores y una mejora del 19 % en la recuperación de cuentas por cobrar, lo cual representa una ganancia significativa en términos de eficiencia financiera (Lontchi et al., 2023).

El estudio también resalta que la falta de habilidades técnicas y financieras sigue siendo una barrera para que las PYMEs aprovechen plenamente las oportunidades que ofrecen las soluciones FinTech. Por ello, los autores recomiendan fortalecer los programas de educación financiera y la capacitación digital dentro de las organizaciones, promoviendo así un entorno más propicio para la innovación y la sostenibilidad empresarial. Finalmente, se concluye que la adopción temprana de tecnologías financieras contribuye no solo al acceso a servicios bancarios formales y mejores condiciones crediticias, sino también al fortalecimiento de la inclusión financiera y la resiliencia empresarial frente a futuras crisis económicas (Lontchi et al., 2023).

Relevancia para el estudio

Este caso resulta especialmente relevante para la presente investigación, ya que demuestra de manera empírica cómo la adopción de herramientas tecnológicas financieras puede fortalecer la gestión económica y la sostenibilidad de las PYMEs, incluso en contextos de alta incertidumbre económica. Los hallazgos de Lontchi, Yang y Shuaib (2023) muestran que la incorporación de soluciones FinTech no solo moderniza los procesos financieros, sino que también contribuye a mejorar la toma de decisiones basada en datos, un principio fundamental de la analítica predictiva.

Además, el estudio subraya el papel determinante de la alfabetización financiera como factor mediador para el éxito de la transformación digital. Esto coincide con los planteamientos de Hair et al. (2021), quienes señalan que el desarrollo de competencias analíticas y financieras en el personal es indispensable para traducir la información en decisiones estratégicas efectivas. En otras palabras, las tecnologías por sí solas no garantizan el mejor desempeño empresarial; su impacto positivo depende de la capacidad de

los usuarios para comprender, interpretar y utilizar los datos que generan.

La investigación también aporta lecciones aplicables al contexto latinoamericano, donde muchas PYMEs aún enfrentan limitaciones de acceso al crédito, baja digitalización y escasa cultura de análisis financiero (Banco Interamericano de Desarrollo, 2023). Los resultados obtenidos en Camerún confirman que la adopción temprana de tecnologías financieras puede mejorar la liquidez, reducir los riesgos asociados al flujo de caja y ampliar las oportunidades de financiación formal, lo que coincide con las metas de impulsar la inteligencia financiera mediante la analítica de datos. En síntesis, este caso apoya la hipótesis central del proyecto al evidenciar que la combinación entre tecnología financiera y alfabetización financiera genera entornos empresariales más resilientes, innovadores y preparados para el uso de herramientas de analítica predictiva en la gestión económica. Por tanto, se constituye en un referente valioso para comprender cómo la integración de tecnología y conocimiento puede potenciar la eficiencia financiera de las PYMEs en países en desarrollo.

Caso 12: Adopción de Tecnologías Financieras y su Influencia en el Acceso al Crédito Bancario de las PYMEs Manufactureras en Economías Emergentes.

Tabla 19.

Adopción de Tecnologías Financieras y su Influencia en el Acceso al Crédito Bancario de las PYMEs Manufactureras en Economías Emergentes.

Elemento de análisis	Descripción
Autor	Rehman, S. U., Al-Shaikh, M., Washington, P. B., Lee, E., Song, Z., Abu-AlSondos, I. A., Shehadeh, M., & Allahham, M.
Año	2023
Título del estudio o documento	FinTech Adoption in SMEs and Bank Credit Supplies: A Study on Manufacturing SMEs
Fuente	Economies (MDPI).
País de estudio	Asia / Medio Oriente.
Contexto	El estudio de Rehman et al. (2023) se realizó en países de Asia y Medio Oriente, donde las pequeñas y medianas empresas manufactureras cumplen un papel fundamental en la economía, pero aún enfrentan grandes retos para acceder a financiación formal. En estas regiones, muchas PYMEs dependen del crédito bancario para sostener sus operaciones, aunque la falta de historial crediticio, la informalidad contable y la escasa adopción tecnológica limitan sus posibilidades. Frente a este escenario, la incorporación de soluciones FinTech como plataformas de pagos digitales, sistemas de facturación electrónica y servicios de financiamiento alternativo ha empezado a cambiar la forma en que los bancos evalúan el riesgo y conceden créditos, permitiendo procesos más transparentes y rápidos (Arner et al., 2020). El estudio buscó comprender cómo estas herramientas tecnológicas están influyendo en la relación entre las PYMEs y las entidades financieras, y de qué manera la digitalización de los procesos financieros puede mejorar el acceso al crédito, la eficiencia operativa y la sostenibilidad económica de las empresas en contextos emergentes.
Tipo de documento	Artículo científico
Principales hallazgos o aportes	Los resultados del estudio de Rehman et al. (2023) mostraron que la adopción de tecnologías financieras (FinTech) tiene un impacto positivo en la relación entre las PYMEs manufactureras y el sistema bancario, especialmente en la

obtención y gestión del crédito. Las empresas que incorporaron plataformas digitales para procesar pagos, gestionar facturas o acceder a servicios de financiamiento alternativo, reportaron mejoras en la transparencia de sus operaciones y una reducción significativa en los tiempos de respuesta de las entidades financieras. Esto se debe a que las soluciones FinTech generan trazabilidad y datos verificables sobre las transacciones, lo que facilita la evaluación del riesgo crediticio y fortalece la confianza entre bancos y empresas. En consecuencia, las PYMEs digitalmente activas pudieron acceder con mayor facilidad a líneas de crédito formales y con condiciones más favorables.

Además, el estudio resaltó que la digitalización financiera no solo beneficia la relación con los bancos, sino que también optimiza los procesos internos de las empresas. La automatización de tareas contables y de flujo de caja permitió reducir errores, mejorar el control financiero y aumentar la eficiencia en el manejo de recursos. Sin embargo, los autores también advierten que la adopción tecnológica debe ir acompañada de capacitación y alfabetización digital, ya que muchas PYMEs aún presentan resistencia al cambio o desconocimiento sobre el uso de estas herramientas. En conjunto, los hallazgos evidencian que las soluciones FinTech representan una vía efectiva para fortalecer la sostenibilidad financiera y la competitividad de las PYMEs en economías emergentes, siempre que exista un ecosistema favorable de inclusión digital y apoyo institucional (Rehman et al., 2023; Arner et al., 2020).

Relevancia para el estudio

Este caso es especialmente útil para el desarrollo de la presente investigación, ya que permite entender cómo la adopción de tecnologías financieras puede transformar la relación entre las PYMEs y el sistema bancario, un aspecto clave para fortalecer la inteligencia financiera en este tipo de organizaciones. Los hallazgos de Rehman et al. (2023) evidencian que las herramientas FinTech no solo mejoran la eficiencia de los procesos financieros, sino que también crean un puente de confianza entre las empresas y las entidades crediticias al ofrecer datos precisos y verificables sobre las operaciones. Esta capacidad de generar información confiable y en tiempo real es un principio central de la analítica predictiva, ya que facilita la toma de decisiones basadas en evidencia y permite anticipar comportamientos financieros futuros.

Asimismo, el estudio destaca la importancia de la digitalización como motor de inclusión financiera en contextos donde muchas PYMEs carecen de acceso al crédito formal, un reto también presente en América Latina. Por eso, este caso aporta una base comparativa valiosa para analizar cómo las soluciones tecnológicas aplicadas al ámbito financiero pueden replicarse o adaptarse al entorno colombiano, fortaleciendo los mecanismos de evaluación crediticia y la gestión de riesgos. En conjunto, la evidencia presentada apoya la hipótesis de que la implementación de herramientas de analítica y automatización en las PYMEs puede generar no solo mayor eficiencia operativa, sino también una relación más sólida y transparente con el sistema financiero, elemento esencial para su sostenibilidad y crecimiento.

Caso 13: Decisiones Empresariales Basadas en Datos: Retos y Resultados de la Analítica en PYMEs del Reino Unido

Tabla 20.
Decisiones Empresariales Basadas en Datos: Retos y Resultados de la Analítica en PYMEs del Reino Unido.

Elemento de análisis	Descripción
Autor	Tawil, A.-R., Mohamed, M., Schmoor, X., Vlachos, K., & Haidar, D.
Año	2024
Título del estudio o documento	Trends and Challenges towards Effective Data-Driven Decision Making in UK Small and Medium-Sized Enterprises: Case Studies and Lessons Learnt from the Analysis of 85 SMEs
Fuente	Big Data and Cognitive Computing (MDPI).
País de estudio	Reino Unido.
Contexto	El estudio realizado por Tawil et al. (2024) se llevó a cabo en el Reino Unido con una muestra de 85 pequeñas y medianas empresas de distintos sectores, con el propósito de analizar cómo las organizaciones están incorporando la toma de decisiones basada en datos y qué factores determinan su efectividad. En un entorno económico cada vez más competitivo y digitalizado, las PYMEs británicas enfrentan el reto de transformar grandes volúmenes de información en conocimiento útil para orientar sus estrategias de negocio. La investigación se desarrolló a lo largo de tres años, en un contexto de transición hacia la adopción de herramientas de inteligencia de negocios (BI) y machine learning, en el que muchas empresas comenzaron a integrar soluciones analíticas para mejorar la eficiencia operativa y la planificación. Sin embargo, también se identificaron limitaciones importantes, como la escasez de personal especializado, la falta de cultura organizacional orientada a los datos y las restricciones presupuestarias que dificultan la implementación de modelos predictivos a gran escala. Este contexto permitió comprender de forma integral los avances, desafíos y aprendizajes de las PYMEs en su camino hacia una gestión verdaderamente impulsada por datos.
Tipo de documento	Artículo científico

Principales hallazgos o aportes	Los resultados del estudio de Tawil et al. (2024) mostraron que la adopción de enfoques basados en datos ha tenido un impacto directo y medible en la productividad y competitividad de las pequeñas y medianas empresas del Reino Unido. A lo largo de tres años de observación, las PYMEs que implementaron sistemas de inteligencia de negocios (BI) y modelos de machine learning lograron incrementos en productividad de entre el 10 % y el 18 %. Estas organizaciones utilizaron los datos no solo para analizar su desempeño, sino también para anticipar comportamientos del mercado, optimizar la gestión de inventarios y mejorar la planificación de la producción. Uno de los aportes más relevantes del estudio es que la toma de decisiones sustentada en datos permitió reducir la incertidumbre operativa y aumentar la capacidad de respuesta ante cambios en la demanda o en los costos de operación, generando un efecto positivo en la rentabilidad y sostenibilidad de las empresas. Por otro lado, el estudio identificó barreras significativas que limitan la consolidación de una cultura de gestión basada en datos. Entre las principales se encuentran la falta de talento especializado en analítica, la escasa integración entre los sistemas de información y la resistencia al cambio en niveles directivos. A pesar de estos desafíos, las empresas que apostaron por desarrollar una cultura organizacional orientada a los datos evidenciaron mayores beneficios a largo plazo, especialmente en la automatización de procesos y en la eficiencia en la toma de decisiones. Los autores concluyen que el éxito de las estrategias de analítica en PYMEs no depende únicamente de la tecnología implementada, sino de la capacidad de la organización para alinear sus recursos humanos, procesos y objetivos estratégicos en torno a la gestión del conocimiento y la transformación digital (Tawil et al., 2024).
Relevancia para el estudio	Este caso resulta especialmente relevante para la investigación, ya que evidencia cómo la adopción de una cultura organizacional basada en datos puede transformar la gestión y el rendimiento de las PYMEs. Los hallazgos de Tawil et al. (2024) demuestran que la integración de herramientas de machine learning y sistemas de inteligencia de negocios no solo optimiza la productividad, sino que también mejora la capacidad de las empresas para anticiparse a escenarios financieros, un aspecto directamente relacionado con la analítica predictiva aplicada a la inteligencia financiera.

En el contexto del Reino Unido, las PYMEs que invirtieron en capacidades analíticas lograron utilizar sus datos como un activo estratégico, fortaleciendo la toma de decisiones y reduciendo la dependencia de la intuición o la experiencia empírica en la gestión económica.

Además, el estudio ofrece aprendizajes valiosos sobre los factores que influyen en el éxito o el fracaso de la transformación digital, especialmente en organizaciones con recursos limitados. La identificación de obstáculos como la falta de talento, la resistencia cultural y las limitaciones presupuestarias permite contextualizar desafíos similares que enfrentan las PYMEs en América Latina, incluida Colombia. Por esta razón, este caso proporciona una base comparativa sólida para analizar cómo las estrategias de analítica de datos pueden adaptarse a distintos entornos económicos y culturales, contribuyendo a la formulación de modelos que impulsen la sostenibilidad financiera mediante el uso inteligente de la información.

Caso 14: Aplicación de la Inteligencia Artificial en la Toma de Decisiones Financieras de las PYMEs en Nigeria

Tabla 21.
Aplicación de la Inteligencia Artificial en la Toma de Decisiones Financieras de las PYMEs en Nigeria.

Elemento de análisis	Descripción
Autor	Okeke, N. I., Bakare, O. A., & Achumie, G. O.
Año	2024
Título del estudio o documento	Artificial Intelligence in SME Financial Decision-Making: Tools for Enhancing Efficiency and Profitability
Fuente	Research Journal of Multidisciplinary Studies.
País de estudio	Nigeria.
Contexto	El estudio de Okeke, Bakare y Achumie (2024) se llevó a cabo en Nigeria con el propósito de analizar cómo la inteligencia artificial (IA) y el aprendizaje automático (machine learning) están transformando los procesos de toma de decisiones financieras en las pequeñas y medianas empresas. En un entorno donde las PYMEs representan más del 80 % del tejido empresarial, pero enfrentan grandes limitaciones de acceso a financiación, control de gastos y gestión de liquidez, el uso de tecnologías inteligentes se ha convertido en una alternativa para mejorar la eficiencia y la rentabilidad. La investigación examina tanto la adopción de herramientas automatizadas de contabilidad, como sistemas predictivos para el flujo de caja y algoritmos de detección de anomalías en registros contables. Este enfoque permite entender cómo la IA contribuye a reducir los errores humanos, optimizar los tiempos de análisis y fortalecer la capacidad de respuesta ante fluctuaciones del mercado financiero, posicionando a la tecnología como un aliado clave para la sostenibilidad empresarial.
Tipo de documento	Artículo científico
Principales hallazgos o aportes	Los resultados del estudio revelan que la implementación de sistemas basados en inteligencia artificial generó mejoras significativas en la eficiencia operativa y la precisión financiera de las PYMEs nigerianas. De acuerdo con Okeke et al. (2024), las empresas que integraron soluciones de automatización contable y análisis predictivo lograron reducir los errores en los procesos financieros hasta en un 30 %,

además de agilizar la toma de decisiones en un 25 %. Estas herramientas, basadas en modelos de aprendizaje automático, permitieron predecir variaciones de flujo de caja, optimizar la planificación de gastos e identificar patrones irregulares en los registros contables. El estudio resalta que la adopción de la IA no solo mejora la exactitud de los informes financieros, sino que también incrementa la capacidad de las empresas para reaccionar ante riesgos, evitando pérdidas por decisiones tardías o información incompleta.

Asimismo, los autores destacan que el principal reto para la adopción de estas tecnologías radica en la falta de conocimiento técnico y en la inversión inicial requerida para su implementación. Sin embargo, las PYMEs que superaron esas barreras obtuvieron beneficios tangibles, como una mejor asignación de recursos humanos, reducción de costos administrativos y un aumento progresivo en la rentabilidad anual. El estudio concluye que la IA tiene un enorme potencial para fortalecer la inteligencia financiera de las PYMEs, al ofrecer información oportuna y automatizar procesos críticos que antes dependían de la experiencia subjetiva de los gestores financieros. Esta evidencia empírica reafirma el valor de la analítica avanzada como herramienta de apoyo a la toma de decisiones estratégicas.

Relevancia para el estudio

Este caso resulta fundamental para la investigación, ya que demuestra cómo la inteligencia artificial puede integrarse de manera práctica en la gestión financiera diaria de las PYMEs, fortaleciendo los pilares de la analítica predictiva aplicada a la inteligencia financiera. Los hallazgos de Okeke et al. (2024) permiten comprender que el uso de modelos de machine learning y herramientas automatizadas no solo mejora la eficiencia, sino que también promueve una gestión más proactiva y basada en datos. Este enfoque coincide directamente con los objetivos de la investigación, al evidenciar cómo la tecnología puede ser un medio para anticipar resultados financieros, minimizar errores y optimizar la toma de decisiones empresariales.

Además, el estudio aporta una visión comparativa interesante con relación a contextos latinoamericanos, donde las PYMEs enfrentan desafíos similares en términos de digitalización, acceso a talento especializado y sostenibilidad financiera. La experiencia nigeriana muestra que la adopción gradual de herramientas de IA puede generar un cambio cultural hacia

una gestión más analítica y menos empírica, contribuyendo a la eficiencia organizacional y a la competitividad en entornos dinámicos. Por ello, este caso fortalece la base teórica y práctica de la investigación, ofreciendo evidencia concreta sobre el impacto real de la IA en la optimización financiera de las pequeñas y medianas empresas.

Caso 15: Modelos Predictivos Basados en Inteligencia Artificial para la Gestión Financiera de PYMEs en Economías Emergentes

Tabla 22.
Modelos Predictivos Basados en Inteligencia Artificial para la Gestión Financiera de PYMEs en Economías Emergentes.

Elemento de análisis	Descripción
Autor	Okwaraoha, F. C., Atakora, D. A., & Morenikeji, A. W.
Año	2024
Título del estudio o documento	Role of Artificial Intelligence and Machine Learning in Financial Modeling Platforms for SMEs and Financial Institutions
Fuente	International Journal of Artificial Intelligence in Business (IJAIB).
País de estudio	Internacional (África y Asia).
Contexto	El estudio realizado por Okwaraoha, Atakora y Morenikeji (2024) presenta una revisión integral sobre la aplicación de la inteligencia artificial (IA) y el aprendizaje automático (machine learning) en plataformas de modelado financiero utilizadas por pequeñas y medianas empresas (PYMEs) y entidades financieras en regiones de África y Asia. El propósito central de la investigación es comprender cómo estas tecnologías están transformando los métodos tradicionales de evaluación del riesgo, predicción del rendimiento financiero y gestión del capital. En contextos donde las PYMEs operan con altos niveles de incertidumbre y limitados recursos analíticos, la IA se ha convertido en una herramienta estratégica para mejorar la exactitud de los pronósticos y reducir las pérdidas asociadas a decisiones financieras imprecisas. El artículo recopila evidencia empírica de múltiples estudios recientes, abarcando modelos predictivos que combinan redes neuronales, algoritmos de regresión y aprendizaje supervisado para anticipar riesgos crediticios y flujos de caja, evidenciando el potencial de la tecnología como soporte para una toma de decisiones más informada y confiable.
Tipo de documento	Artículo científico
Principales hallazgos o aportes	Los autores identificaron que el uso de algoritmos de <i>machine learning</i> en plataformas de modelado financiero ha permitido aumentar en promedio un 25 % la precisión en la predicción

de riesgos frente a los métodos estadísticos tradicionales. Esta mejora se traduce en decisiones de crédito más seguras, una mejor asignación de capital y una reducción significativa en los niveles de morosidad. Las herramientas analizadas incluyen sistemas basados en árboles de decisión, regresión logística y redes neuronales artificiales, las cuales permiten procesar grandes volúmenes de información financiera y no financiera, como comportamiento de pago, reputación digital o interacciones comerciales. Gracias a estos avances, tanto las PYMEs como las instituciones financieras han logrado mejorar su capacidad de análisis y respuesta ante riesgos, especialmente en entornos donde la información estructurada es escasa o de baja calidad.

Sin embargo, el estudio también subraya varios desafíos que limitan la adopción de estas tecnologías, entre ellos la falta de estandarización de datos, la complejidad en la interpretación de los modelos y la necesidad de personal con conocimientos avanzados en analítica. Aun así, los autores destacan que la implementación gradual de la IA en el ámbito financiero puede impulsar una transformación estructural en la manera en que las PYMEs gestionan el riesgo y planifican su crecimiento. En síntesis, la revisión pone de manifiesto que los modelos predictivos basados en IA son una herramienta clave para mejorar la precisión y la eficiencia de los procesos financieros, fortaleciendo la estabilidad y sostenibilidad de las empresas en economías emergentes (Okwaraoha et al., 2024).

Relevancia para el estudio

Este caso aporta una perspectiva global y actual sobre el papel del machine learning en la construcción de modelos financieros inteligentes, lo que resulta directamente aplicable al propósito central de la investigación. Los hallazgos de Okwaraoha et al. (2024) reafirman que las herramientas de IA no solo mejoran la exactitud de los análisis financieros, sino que también permiten anticipar comportamientos económicos y riesgos futuros, elementos fundamentales en la analítica predictiva aplicada a la inteligencia financiera de las PYMEs. Este enfoque coincide plenamente con la línea del proyecto, que busca identificar estrategias tecnológicas viables para fortalecer la toma de decisiones financieras basadas en datos.

Además, el estudio tiene una relevancia especial para contextos como el colombiano, donde las PYMEs enfrentan limitaciones similares a las observadas en África y Asia. Las lecciones obtenidas en estos mercados emergentes ofrecen una

guía valiosa sobre cómo implementar soluciones tecnológicas de bajo costo y alta eficiencia que contribuyan a la sostenibilidad financiera. De esta manera, el caso 5 no solo amplía la comprensión sobre el potencial de la IA en las finanzas empresariales, sino que también aporta evidencia concreta para sustentar la aplicabilidad de la analítica predictiva como herramienta estratégica para el desarrollo económico.

Anexo 4

Entrevistas Empresarios PYMES

Entrevista 1: Maikol Bonilla - CTO Chief Technology Officer

- ❖ **Nombre del entrevistado:** Maikol Bonilla Gil
- ❖ **Cargo:** CTO - Chief Technology Officer
- ❖ **Sector empresarial:** Tecnológico
- ❖ **Tamaño empresa (empleados):** 10-20
- ❖ **Nombre Empresa:** Bitsquid SAS - 901713594

Preguntas principales

1. ¿Podría describir brevemente su rol dentro de la empresa y las decisiones financieras que usted toma regularmente?

Soy el CTO de Bitsquid SAS, responsable de la dirección tecnológica y la estrategia de producto de Lunts, nuestra app de citas para estudiantes y egresados. Participo en decisiones financieras relacionadas con inversiones en infraestructura tecnológica, contratación de servicios cloud (GCP), herramientas de analítica y marketing digital, así como la evaluación de costos y retorno sobre inversión (ROI) de nuevas funcionalidades y experimentos de crecimiento.

2. ¿Qué tipos de datos financieros y operativos recopila su empresa actualmente?

Recopilamos datos financieros como ingresos por suscripciones premium (y premium para estudiantes), ingresos por publicidad en AdMob, costos de adquisición de usuarios, gastos

operativos y presupuestos de marketing.

En cuanto a datos operativos,

medimos métricas de engagement, como swipes, matches, mensajes enviados, retención de usuarios, conversiones a planes premium, rendimiento de campañas publicitarias.

3. ¿Han probado o usan herramientas para el análisis de datos o predicción? ¿Para qué procesos?

Sí. Utilizamos herramientas como Firebase Analytics, RevenueCat, Google Data Studio y BigQuery para análisis de comportamiento y monetización.

En la parte predictiva, hemos hecho pruebas de modelos de segmentación y predicción de tasas de abandono para anticipar bajas de usuarios y optimizar campañas de retención.

4. ¿Puede contarnos un caso en que una predicción o dato influyó en una decisión importante? ¿Cuál fue el resultado?

Realizamos un análisis del retorno económico generado por la publicidad de AdMob, comparando los ingresos por usuario con el costo de adquisición y retención.

A partir de esos datos, estimamos el punto de equilibrio entre ingresos por anuncios y por suscripciones, lo que nos permitió definir los precios óptimos para los planes Premium y Premium para Estudiantes.

El resultado fue una mejor rentabilidad general y un aumento en la conversión a suscripciones pagas, manteniendo un equilibrio sostenible entre ingresos por publicidad y suscripciones.

5. ¿Qué factores considera que facilitan o dificultan la adopción de tecnologías analíticas en su empresa?

Factores que facilitan:

- Una cultura empresarial orientada a la toma de decisiones basadas en datos, desde producto hasta marketing.
- La disponibilidad de datos estructurados y trazables provenientes de diversas fuentes (app, backend, monetización, campañas).
- Nuestra infraestructura cloud escalable (basada en Google Cloud y Firebase), que facilita la integración con herramientas analíticas y modelos de machine learning.
- Un equipo técnico flexible y con mentalidad experimental, dispuesto a iterar y validar hipótesis rápidamente.

Factores que dificultan:

- La falta de especialistas dedicados exclusivamente a ciencia de datos y machine learning, lo que limita la profundidad de los modelos predictivos.
- La priorización de recursos hacia desarrollo de producto frente a iniciativas de analítica avanzada.
- Los costos asociados a herramientas premium y consultorías especializadas, que pueden ser significativos en etapas tempranas de crecimiento.
- La necesidad de mantener el cumplimiento normativo y la privacidad de los datos de los usuarios, que agrega complejidad a cualquier proyecto analítico.

6. ¿Qué beneficios concretos cree que traería un sistema de analítica predictiva para su negocio?

- Mejor segmentación de usuarios y personalización de la experiencia.
- Predicción de abandono y comportamiento de compra, lo que permitiría acciones preventivas.
- Optimización de precios y promociones en los planes premium.
- Mejor planificación financiera basada en proyecciones de ingresos y retención.

7. ¿Qué riesgos o preocupaciones tendría frente a la implementación de estas tecnologías?

Privacidad y cumplimiento normativo, especialmente por el tipo de datos personales que manejamos.

Dependencia tecnológica de terceros proveedores.

Sesgos en los modelos predictivos que podrían afectar la equidad o la precisión de las decisiones automatizadas.

8. ¿Qué tipo de apoyo considera necesario para adoptar este tipo de herramientas (formación, asesoría, financiación)?

Principalmente:

- Asesoría técnica y estratégica en la implementación de modelos predictivos.

- Capacitación del equipo en análisis avanzado y ciencia de datos aplicada al producto.
- Eventualmente financiación o créditos tecnológicos para cubrir costos iniciales de infraestructura y consultoría.

9. ¿Cómo visualiza la gestión financiera de su empresa dentro de 3–5 años si integrara analítica predictiva?

Tendríamos una gestión financiera altamente automatizada y proactiva, con proyecciones en tiempo real de ingresos, retención y ROI por canal de adquisición.

La toma de decisiones sería más ágil y basada en modelos predictivos confiables, permitiendo optimizar presupuestos, identificar oportunidades de crecimiento y reaccionar rápidamente ante cambios en el mercado.

10. ¿Hay algo más que considere importante que no le haya preguntado?

Sí. Considero fundamental que las soluciones de analítica predictiva estén alineadas con la experiencia del usuario final. En el caso de una app de citas, predecir comportamientos sin perder la autenticidad y privacidad del usuario es clave para mantener la confianza y sostenibilidad del producto a largo plazo.

Consentimiento Informado

Yo, Maikol Bonilla Gil declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada.

Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: Maikol Bonilla

Fecha: 16 de octubre 2025

Entrevista 2: Rene Ricardo Contreras Rodriguez – Director de Ingeniería

- ❖ **Nombre del entrevistado:** Rene Ricardo Contreras Rodriguez
- ❖ **Cargo:** Director de Ingeniería
- ❖ **Sector empresarial:** Tecnológico
- ❖ **Tamaño empresa (empleados):** 10
- ❖ **Nombre Empresa:** Innova Networks SAS

Preguntas principales

1. ¿Podría describir brevemente su rol dentro de la empresa y las decisiones financieras que usted toma regularmente?

Liderar la parte técnica, incluyendo soporte, despliegue de soluciones y acompañamiento técnico al área comercial, igualmente la toma decisiones financieras relacionadas con la estimación de tiempos y recursos para los proyectos, lo que impacta directamente en los costos y la selección de nuevos productos para el portafolio.

2. ¿Qué tipos de datos financieros y operativos recopila su empresa actualmente?

Por un lado, en la parte operativa se recopilan datos sobre los tiempos de despliegue de proyectos para estimar los recursos necesarios en futuros proyectos, para la parte financiera, de manejan proyecciones de ventas para hacer pronósticos. Esto adicional a los requisitos de ley que se debe cumplir, como son los datos contables como impuestos y facturación.

3. ¿Han probado o usan herramientas para el análisis de datos o predicción? ¿Para qué procesos?

La empresa no utiliza herramientas de predicción o análisis de datos automatizado. No obstante, recientemente se implementó un CRM para visualizar datos de ventas y proyecciones, pero no tiene capacidades predictivas.

4. ¿Puede contarnos un caso en que una predicción o dato influyó en una decisión importante? ¿Cuál fue el resultado?

Aunque no usan herramientas predictivas, se utilizan datos de la experiencia para hacer estimaciones. Por ejemplo, se calcula los costos financieros de posibles riesgos en los proyectos como multas por incumplimiento y se asignan bolsas de dinero en el presupuesto para cubrirlos. Esto ha resultado en superávits cuando los riesgos no se materializan y ha evitado pérdidas cuando sí ocurren.

5. ¿Qué factores considera que facilitan o dificultan la adopción de tecnologías analíticas en su empresa?

Las principales dificultades son: a) El desconocimiento de las herramientas y cómo implementar modelos. b) La empresa, con 10 años de trayectoria, apenas está comenzando a consolidar su data en un CRM. c) La cultura organizacional, donde se prefiere tomar decisiones basadas en la experiencia personal.

Ahora bien, como facilitador se tienen que, al ser una empresa de tecnología, hay una disposición natural hacia la adopción de nuevas herramientas. Además, se cuenta con el capital humano y con las capacidades técnicas para implementar y gestionar estas tecnologías.

6. ¿Qué beneficios concretos cree que traería un sistema de analítica predictiva para su negocio?

Como beneficio principal es que permitiría cuantificar mejor la probabilidad y el impacto de los riesgos en los proyectos, ajustando las reservas de dinero y siendo más competitivos. También ayudaría a estimar la demanda futura de servicios, lo que mejoraría la planificación, el modelo de negocio y la negociación con clientes.

7. ¿Qué riesgos o preocupaciones tendría frente a la implementación de estas tecnologías?

La principal preocupación es la dificultad para cuantificar el ROI de la inversión, ya que es complicado medir el ahorro o ganancia generada por una predicción acertada. Otro riesgo importante es que las predicciones fallen, lo que impactaría negativamente la credibilidad de la herramienta y podría generar pérdidas si no se asignaron fondos de contingencia.

8. ¿Qué tipo de apoyo considera necesario para adoptar este tipo de herramientas (formación, asesoría, financiación)?

Como principal apoyo es la formación, capacitación o la asesoría para saber qué datos usar, como usarlos y para que usarlos, igualmente cómo evitar sesgos y por dónde empezar, es

decir el conocimiento tenido. La financiación no es la principal barrera inicial, ya que existen herramientas de software libre para comenzar como Power Bi, Python, RStudio, etc.

9. ¿Cómo visualiza la gestión financiera de su empresa dentro de 3–5 años si integrara analítica predictiva?

A través de la analítica predictiva, dentro de 3 a 5 años se tendría una gestión más eficiente, con decisiones basadas en datos en lugar de la heurística o la experiencia, permitiendo optimizar la inversión del capital y las utilidades para acelerar el crecimiento de la empresa.

10. ¿Hay algo más que considere importante que no le haya preguntado?

No.

Consentimiento Informado

Yo, Rene Ricardo Contreras Rodriguez declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada. Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: *Rene Ricardo Contreras Rodriguez*

Fecha: 02 de noviembre 2025

Entrevista 3: Mauricio Rojas – Gerente administrativo y financiero

- ❖ **Nombre del entrevistado:** Mauricio Rojas
- ❖ **Cargo:** Gerente administrativo y financiero
- ❖ **Sector empresarial:** Metalúrgico – Industrial
- ❖ **Tamaño empresa (empleados):** 8
- ❖ **Nombre Empresa:** Industrias Metálicas RP SAS

Preguntas principales

1. ¿Podría describir brevemente su rol dentro de la empresa y las decisiones financieras que usted toma regularmente?

Soy el encargado de supervisar y asegurar el correcto control de los registros contables de la empresa, garantizando que toda la información financiera sea precisa, completa y oportuna.

Entre mis funciones se incluye la revisión y análisis de los estados financieros balances generales, estados de resultados y flujos de efectivo con el objetivo de evaluar la situación económica y financiera de la organización. Asimismo, realizo un seguimiento constante del ciclo de trabajo y del capital de trabajo, identificando oportunidades de mejora en los procesos contables y operativos para optimizar la eficiencia y apoyar la toma de decisiones estratégicas.

Además, tengo a mi cargo la administración de los recursos de la empresa, velando por su uso adecuado y la correcta asignación presupuestaria. También participo en la gestión y coordinación de proyectos, desde la planificación hasta la ejecución, asegurando que se cumplan

los objetivos establecidos en tiempo y forma. Mi labor busca contribuir al crecimiento sostenible de la empresa mediante una gestión financiera sólida, transparente y orientada a resultados.

2. ¿Ha escuchado o ha utilizado herramientas basados en machine Learning o analítica de datos, Si es así, ¿para qué propósito?

Soy el encargado de supervisar y asegurar el correcto control de los registros contables de la empresa, garantizando que toda la información financiera sea precisa, completa y oportuna. Entre mis funciones se incluye la revisión y análisis de los estados financieros balances generales, estados de resultados y flujos de efectivo con el objetivo de evaluar la situación económica y financiera de la organización. Además, llevo un seguimiento constante del ciclo de trabajo y del capital de trabajo, identificando oportunidades de mejora en los procesos contables y operativos para optimizar la eficiencia. Utilizamos herramientas como Power BI y tablas de Excel para el control de producción, lo que nos permite realizar un monitoreo detallado y en tiempo real de los indicadores clave de desempeño.

3. ¿Qué factores considera que facilitan o dificultan la adopción de tecnologías analíticas en su empresa?

Uno de los temas que enfrentamos es el desconocimiento de herramientas de Machine Learning y modelos predictivos, los cuales actualmente no están disponibles para nosotros. Aunque tenemos un conocimiento básico sobre cómo funcionan estas herramientas, no contamos con la capacitación adecuada para utilizarlas de manera eficiente. Sin embargo, estamos convencidos de que, si tuviéramos acceso a estas tecnologías y el conocimiento necesario para

implementarlas, serían una excelente herramienta para mejorar nuestros procesos. Creemos que estas herramientas podrían ayudarnos significativamente a optimizar recursos y ahorrar costos, lo que sería un beneficio clave para la empresa.

4. ¿Qué beneficios concretos cree que traería un sistema de analítica predictiva para su negocio?

El control de inventarios ha sido de gran ayuda para la empresa. Mantener el stock organizado y actualizado, junto con el seguimiento constante de las ventas y el flujo de caja a lo largo del tiempo, nos ha permitido tomar decisiones más informadas. Estos elementos han sido clave para mejorar la eficiencia operativa y asegurar que tengamos los recursos disponibles cuando los necesitamos. En general, estos procesos nos han brindado una visión más precisa de nuestra situación financiera y nos han ayudado a optimizar nuestras operaciones.

5. ¿Qué riesgos o preocupaciones tendría frente a la implementación de estas tecnologías?

No se considera que tenga un riesgo alto, ya que consideramos que El desconocimiento de Machine Learning es una de nuestras principales limitaciones. Al no contar con el conocimiento necesario, no sabemos hasta qué punto podríamos aprovechar estas herramientas de manera efectiva. En nuestro caso, tendríamos que considerar la contratación de un experto externo a tiempo completo para implementar y gestionar estas actividades, lo cual no sería una opción financieramente viable a corto plazo. Sin embargo, no consideramos que esto represente un riesgo elevado, ya que entendemos que las herramientas de Machine Learning tienen un retorno

de inversión que puede ser significativo a mediano o largo plazo, lo que justificaría la inversión inicial una vez que se logre una integración adecuada en los procesos de la empresa.

6. ¿Qué tipo de apoyo considera necesario para adoptar este tipo de herramientas (formación, asesoría, financiación)?

Considero que, inicialmente, muchos emprendedores que lideran pequeñas y medianas empresas (PYMEs) tienden a ser reacios a los cambios, ya que temen que estos puedan incrementar los costos de la empresa o consideran que no son tan necesarios. Sin embargo, herramientas como Machine Learning y otras tecnologías pueden ofrecer un valor significativo a largo plazo. Para fomentar su adopción, sería ideal que el gobierno incentivara el uso de estas herramientas, ofreciendo apoyo a las PYMEs. Esto podría incluir incentivos fiscales o facilidades en áreas como importaciones y capacitación en temas financieros, lo que generaría un impulso para el futuro de la empresa. De esta forma, los emprendedores podrían estar más motivados a invertir en tecnologías que, aunque representen una inversión inicial, traigan beneficios a largo plazo.

7. ¿Cómo visualiza el papel de analista y el Machine Learning en el futuro de la gestión empresarial de su organización?

En cuanto al análisis de datos, hemos trabajado hasta cierto punto, pero de manera superficial, utilizando datos existentes y centrándonos en temas básicos. Sin embargo, nos gustaría poder profundizar más en áreas como predicciones y análisis avanzados, especialmente en los sectores comerciales y de marketing. Creemos que, al integrar estos análisis más

completos, podríamos tomar decisiones más informadas y estratégicas que impulsaran el crecimiento y la eficiencia de la empresa

Consentimiento Informado

Yo, Mauricio Rojas declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada. Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: *Mauricio Rojas*

Fecha: 29 de octubre 2025

Anexo 5

Entrevistas a Expertos en Machine Learning

Entrevista 1: Andrés Felipe Cruz Salinas – Member of Technical Staff

- ❖ **Nombre del entrevistado:** Andrés Felipe Cruz Salinas
- ❖ **Cargo/experiencia:** Member of Technical staff / AI Researcher
- ❖ **Años de experiencia en ML:** 5+ años
- ❖ **Sector:** Generative AI

Preguntas principales

1. Desde su experiencia, ¿cuáles son los factores técnicos y organizacionales que determinan la adopción o resistencia de ML en PYMEs?

Algo común en cualquier organización que entrene modelos de ML exitosamente es el acceso libre a los datos para entrenar los modelos. Debido a restricciones de privacidad o seguridad, es posible que se deba usar infraestructura o protocolos especiales para iterar ágilmente en entrenar nuevos modelos. Fuera de esto, definir los protocolos de evaluación sólidamente y de ser posible separar organizacionalmente los responsables de la evaluación y los del entrenamiento, es una manera efectiva de tener una visión sin sesgo de la calidad de los modelos que se entrenan.

2. ¿Qué modelos o técnicas considera más viables para predicción financiera en PYMEs?

Regresión lineal y en general modelos lineales. Modelos XGBoost para clasificación y regresión. Modelos de análisis de series temporales para predecir patrones sobre el tiempo. También considero útil usar conocimiento del dominio para transformar un problema más grande (predecir un fenómeno complejo) en subproblemas que a través de un modelo analítico sencillo o análisis de expertos pueda resolver el problema grande que se quiere resolver.

3. ¿Cómo recomienda integrar modelos predictivos dentro de tableros BI para aportar valor operativo?

A parte de visualizar las predicciones de los modelos de manera clara y concisa, mi recomendación principal es siempre visualizar los intervalos de confianza de los modelos que se estén usando, ya que esto ayuda a tener una percepción realista de hasta qué punto se puede confiar en el modelo. Por otro lado, si el modelo ha sido evaluado en nuevos datos que no han sido incluidos en sus datos de entrenamiento, es bastante útil ilustrar en los tableros de BI el error de predicción del modelo comparado a los datos reales. Esto permite entender hasta qué punto el modelo sigue siendo útil, o si debe ser adaptado a una nueva distribución de datos.

4. ¿Qué métricas o métodos sugiere para validar un modelo en contexto PYME?

Métricas específicas dependen bastante del problema concreto que se quiera resolver en una PYME. De manera general, sugiero mantener los conjuntos de datos destinados para validación completamente separados de los datos de entrenamiento, sin embargo, recordando que ambos deben provenir de la misma distribución. También realizar evaluaciones estratificadas en lugar de promediar una métrica sobre distintas poblaciones. Esto ayuda a tener una visión más

precisa de la calidad del modelo, e interpretabilidad en lugar de intentar optimizar una única métrica.

5. ¿Qué prácticas de gobernanza y ética recomienda implementar en proyectos de ML?

Este es un tema complejo, el cual en mi opinión debe estar guiado por la misión y la visión de la organización que está implementando proyectos de ML. A grosso modo prácticas generales incluyen: manejo de datos responsables de acuerdo a los estándares que se manejen de seguridad y privacidad, delinear transparentemente el origen (modelo o humano) de determinadas métricas o decisiones, mitigación de sesgo a distintas poblaciones (si aplica), y una evaluación responsable de cuándo tiene sentido usar un modelo predictivo teniendo en cuenta que la responsabilidad de las decisiones siempre recae sobre las personas, no sobre los modelos.

6. ¿Podría mencionar un caso exitoso donde ML haya generado impacto en finanzas de PYMEs o empresas similares?

Un caso muy conocido es el de PayPal, que implementó modelos de machine learning para detectar fraudes financieros en transacciones de pequeños negocios y emprendedores alrededor del mundo. Antes, muchos comercios sufrían pérdidas por cargos fraudulentos difíciles de identificar, pero con ML, PayPal logró analizar patrones en tiempo real y bloquear operaciones sospechosas en segundos. Esto no solo redujo significativamente el fraude, sino que generó mayor confianza para que miles de PYMEs pudieran vender en línea con seguridad, impulsando su crecimiento y permitiéndoles competir globalmente.

7. ¿Qué arquitectura o herramientas recomendaría para comenzar en una PYME con recursos limitados?

Recomiendo usar herramientas ligeras para la limpieza y filtro de datos y solo empezar a incrementar la complejidad conforme haya un volumen más grande de datos. Por ejemplo, empezar con Pandas y no frameworks con orquestación más compleja, pues requiere invertir más en infraestructura. En el lado de modelado, sugiero usar modelos de bajo costo para entrenar como regresión lineal y similares, sólo incrementando la complejidad al analizar la distribución de los datos y el problema que se está atacando. Por ejemplo, entrenar primero modelos sencillos pero interpretables desde cero, en lugar de usar modelos fundacionales más complejos y costosos de entrenar. Esto además sirve para establecer una “baseline” clara al comienzo, y permite evaluar el ROI a medida que se introduce complejidad.

8. ¿Qué pasos concretos debería seguir una PYME en los próximos 6 meses para avanzar en inteligencia financiera con analítica predictiva?

Lo más importante es recolectar datos, limpiarlos, filtrarlos y entenderlos. Este no es solo un primer paso, sino algo en lo que se debe invertir igual o más que en entrenar modelos predictivos. Luego de tener datos limpios para trabajar, es más sencillo empezar a entrenar modelos predictivos.

9. ¿Podría recomendar lecturas, recursos o casos útiles para esta investigación?

The Elements of Statistical Learning, Tibshirani. Este libro cubre sólidamente los modelos más sencillos que vale la pena intentar primero.

10. ¿Desea agregar algún comentario final o recomendación adicional?

Mi área de experticia es en el desarrollo de nuevos modelos fundacionales más que en la aplicación a PYMES o similares. Sin embargo, creo que estos tres patrones son bastante comunes en el éxito de proyectos de ML es: ser 100% estricto en los protocolos de evaluación, siempre usar modelos que se saben son exitosos, y tener un “baseline” sencillo para comparar los beneficios de nuevos experimentos (datos, distintos modelos, etc).

Consentimiento Informado

Yo, Andrés Felipe Cruz Salinas declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada. Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: *Andrés Cruz*

Fecha: 21 de octubre 2025

Entrevista 2: Patricia Cifuentes – Profesional especializado

- ❖ **Nombre del entrevistado:** Patricia Cifuentes
- ❖ **Cargo/experiencia:** Profesional especializado / Superintendencia Nacional de Salud
- ❖ **Años de experiencia en ML:** 20+ años
- ❖ **Sector:** Salud

Preguntas principales

1. Desde su experiencia, ¿cuáles son los factores técnicos y organizacionales que determinan la adopción o resistencia de ML en PYMEs?

La moda actual en la implementación de Inteligencia artificial y los lineamientos de política pública que incentivan la adopción de las misma, como por ejemplo los documentos CONPES, generan una presión positiva para que las PYMES exploren herramientas en distintos niveles (básico, intermedio, avanzado), aumentando el interés e intención de uso.

El mayor obstáculo es confundir la compra de herramientas tecnológicas con la construcción de capacidades. Se requieren bases estadísticas básicas, intermedias y avanzadas, conocimiento de modelos y habilidades para traducir el análisis en valor. Además del software, es clave invertir en plataformas de procesamiento y almacenamiento adecuadas, más allá del computador de escritorio. La falta de estas inversiones genera resistencia y adopciones superficiales.

Igualmente, los desarrollos analíticos deben orientarse a generar valor, identificando casos de uso correctos y midiendo resultados. Adoptar la IA por moda, sin claridad de objetivos y sin capacidades, conduce a esfuerzos ineficientes y frustración organizacional.

2. ¿Qué modelos o técnicas considera más viables para predicción financiera en PYMEs?

En contextos donde no se tiene experiencia básica en economía y estadística, los análisis descriptivos son más fáciles de aplicar y comprender por los tomadores de decisiones. Explorar causalidad básica es deseable, aunque más difícil; bien ejecutada, incrementa la utilidad. En finanzas, lo predictivo ayuda a entender tendencias y lo prescriptivo permite simular acciones para modificarlas. Por su utilidad operativa y estratégica, lo predictivo y prescriptivo es más aplicable, aunque exige mayor madurez de datos y capacidades técnicas.

3. ¿Cómo recomienda integrar modelos predictivos dentro de tableros BI para aportar valor operativo?

La integración debe partir de preguntas bien formuladas que trasciendan la estadística descriptiva. Si las decisiones se toman por intuición, el Business Intelligence (BI) descriptivo puede bastar, si se busca apoyar decisiones basadas en datos, se deben incorporar modelos de Machine Learning alineados a esas preguntas, formando un círculo entre BI y analítica avanzada según la profundidad que se requiera.

Ahora bien, muchas plataformas de BI permiten extensiones y programación limitada para integrar modelos. Aunque la capacidad esté restringida, es factible introducir análisis

avanzados dentro del tablero, siempre que la arquitectura y los flujos de datos soporten el ciclo analítico.

4. Desde su perspectiva, ¿cómo puede el Machine Learning contribuir a la gestión del riesgo financiero en las PYMEs?

El riesgo es la probabilidad de eventos adversos dados factores. El Machine Learning contribuye al análisis causal y al análisis de tendencias en el tiempo. Combinando causalidad y predicción, se estiman probabilidades y se anticipan escenarios de riesgo para intervenir factores y modificar trayectorias. Con madurez, los modelos prescriptivos permiten evaluar acciones para reducir la probabilidad de eventos adversos o aplanar tendencias riesgosas, ofreciendo guías prácticas para la gestión integral del riesgo.

5. ¿Qué prácticas de gobernanza y ética recomienda implementar en proyectos de ML?

La base ética es reconocer la titularidad de los datos personales tanto naturales como jurídicos y cumplir el marco legal de tratamiento de datos establecidos en la Ley 1581 de 2012. El incumplimiento es antiético y este acarrea sanciones. La gobernanza debe evitar usos inadecuados, sesgos y decisiones perjudiciales originadas en análisis defectuosos. Adicional, se debe garantizar que los análisis no induzcan decisiones injustas. La ética práctica exige rigor metodológico y transparencia en el uso de datos y modelos.

6. ¿Podría mencionar un caso exitoso donde ML haya generado impacto en finanzas de PYMEs o empresas similares?

Un organismo territorial municipal incorporó BI y analítica básica facilitando la visualización, comprensión y toma de decisiones sobre inversión, sobregiros y necesidades adicionales. Se evidenció un antes y después, con satisfacción por resultados y avance hacia IA generativa y no generativa para optimizar la gestión pública.

7. ¿Qué arquitectura o herramientas recomendaría para comenzar en una PYME con recursos limitados?

En primer lugar, se debe evitar grandes inversiones iniciales por falta de experiencia y riesgo de costos ocultos. Se puede iniciar con herramientas libres y abiertas, conocer datos y necesidades, y evaluar resultados antes de escalar. Por ejemplo, existen versiones libres de Databricks, Power BI y tableros open source. Una vez después de iniciar, se puede definir las expansiones progresivas con control de costos y criterios de eficiencia y efectividad, evitando sobrecargas por parametrizaciones inadecuadas o almacenamiento mal dimensionado.

8. ¿Qué pasos concretos debería seguir una PYME en los próximos 6 meses para avanzar en inteligencia financiera con analítica predictiva?

El avance exige espejo entre procesos institucionales y procesos informáticos. Deben mapear los datos generados por la operación, verificar suficiencia y calidad, y convertirlos en información y conocimiento para responder preguntas de negocio. Igualmente, empezar con tecnología libre y de fácil uso, asegurando un personal capacitado para usarla, ya que, sin recurso humano adecuado, la tecnología no genera resultados.

9. ¿Podría recomendar lecturas, recursos o casos útiles para esta investigación?

Consultar publicaciones sobre transformación digital del MINTIC y la Agencia Nacional Digital, con bibliografía adicional y lineamientos aplicables a PYMES. Igualmente, revisar documentación de plataformas líderes como Microsoft y Amazon, así como modelos de centros de excelencia que integran componentes de transformación digital.

10. ¿Desea agregar algún comentario final o recomendación adicional?

Valorar el trabajo orientado a PYMES y organizar el abordaje tecnológico bajo lógica integrada de transformación digital, centrada en preguntas y necesidades, no en tendencias pasajeras.

Consentimiento Informado

Yo, Patricia Cifuentes declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada. Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: *Patricia Cifuentes*

Fecha: 30 de octubre 2025

Entrevista 3: Diego Mora - Profesional especializado

- ❖ **Nombre del entrevistado:** Diego Mora
- ❖ **Cargo/experiencia:** Profesional especializado / USA Truck Brokers
- ❖ **Años de experiencia en ML:** 3+ años
- ❖ **Sector:** Seguros

Preguntas principales

1. Desde su experiencia, ¿cuáles son los factores técnicos y organizacionales que determinan la adopción o resistencia de ML en PYMEs?

El incremento constante en el volumen de datos constituye un desafío relevante para las organizaciones. La ejecución de modelos de Machine Learning sobre grandes volúmenes de información puede generar desajustes y márgenes de error que afecten la eficiencia y provoquen retrasos en los procesos de gestión de las PYMEs. Dado que este tipo de empresas se caracteriza por contar con recursos financieros y tecnológicos limitados, la implementación de modelos de Machine Learning puede representar una restricción significativa. Además, no todas las PYMEs están dispuestas a asumir la inversión que implica la adopción de estas tecnologías.

2. ¿Qué modelos o técnicas considera más viables para predicción financiera en PYMEs?

Los modelos de regresión lineal o regularizada pueden contribuir significativamente a la toma de decisiones en una PYME, ya que permiten considerar variables económicas y estimar la

demanda en función del entorno en el que la empresa opera. Un ejemplo de aplicación sería la predicción de variaciones en modelos financieros globales, como posibles incrementos en costos o impuestos estandarizados, los cuales podrían afectar la estructura del negocio. La implementación de un modelo de regresión posibilita predecir, analizar y ejecutar estrategias de manera óptima ante este tipo de cambios, evitando los sesgos y las limitaciones propias de los métodos tradicionales. Además, estos modelos no requieren una alta capacidad computacional ni demandan infraestructura tecnológica compleja para su implementación.

Asimismo, el uso de modelos de regresión favorece la optimización de los recursos y la planificación estratégica dentro de las PYMEs. Al analizar relaciones entre variables como costos de producción, precios de mercado y niveles de ventas, estos modelos permiten identificar patrones y anticipar comportamientos económicos. De esta manera, las empresas pueden tomar decisiones fundamentadas para mejorar su rentabilidad, ajustar sus estrategias de inversión y reducir los riesgos financieros. La aplicación de este tipo de análisis predictivo fortalece la capacidad de las PYMEs para adaptarse a los cambios del entorno y sostener un crecimiento competitivo en el tiempo.

3. ¿Cómo recomienda integrar modelos predictivos dentro de tableros BI para aportar valor operativo?

La implementación de Machine Learning en herramientas de análisis como Power BI o Tableau representa una oportunidad significativa para fortalecer los modelos de gestión escalables en las PYMEs. Estas plataformas, al incorporar algoritmos de aprendizaje automático, permiten automatizar procesos analíticos y mejorar la interpretación de los datos empresariales.

Por ejemplo, un modelo de regresión o de clasificación puede integrarse en Power BI para predecir la demanda de un producto o detectar patrones de comportamiento en los clientes a partir de datos históricos. De este modo, las decisiones estratégicas no se basan únicamente en la intuición, sino en evidencia cuantitativa respaldada por los datos.

Asimismo, la adopción de Machine Learning facilita la unificación de múltiples fuentes de información como hojas de cálculo, sistemas contables, plataformas de ventas en línea o bases de datos de clientes, lo que permite construir modelos predictivos más robustos. Por ejemplo, una PYME que combine los datos de ventas de su tienda física con los del comercio electrónico podría utilizar un modelo de predicción de series temporales para anticipar fluctuaciones en la demanda según temporadas o campañas publicitarias. De igual forma, mediante algoritmos de segmentación (como *k-means*), se pueden identificar grupos de consumidores con características similares y diseñar estrategias personalizadas de marketing o fidelización. En conjunto, estas aplicaciones contribuyen a una toma de decisiones más eficiente, reducen la incertidumbre y promueven una gestión empresarial basada en datos.

4. Desde su perspectiva, ¿cómo puede el Machine Learning contribuir a la gestión del riesgo financiero en las PYMEs?

El Machine Learning puede ser una herramienta clave para mejorar el impacto sobre el cliente final. Al procesar los datos de los sistemas de información, los algoritmos de clasificación o de clustering permiten segmentar a los clientes según sus comportamientos y necesidades. Por ejemplo, al analizar un historial de compras, se puede identificar a clientes frecuentes y a aquellos que realizan visitas esporádicas. Un cliente que compra de manera regular se clasifica

en un grupo distinto al de un cliente ocasional, lo que permite diseñar estrategias personalizadas: los beneficios, descuentos o promociones se asignan según la categoría de cada consumidor.

Este enfoque no solo mejora la experiencia del cliente, al ofrecerle lo que realmente necesita, sino que también optimiza la gestión financiera de la empresa. Al priorizar recursos y beneficios para los clientes que generan mayor valor, la PYME puede reducir costos innecesarios y aumentar la eficiencia en la asignación de incentivos. En consecuencia, la aplicación de Machine Learning no solo contribuye a un marketing más preciso, sino que también fortalece la sostenibilidad económica de la organización.

5. ¿Qué prácticas de gobernanza y ética recomienda implementar en proyectos de ML?

Es fundamental que las personas o usuarios que operan y gestionan los datos estén en contacto directo con la información de manera cotidiana, y que comprendan la importancia de la transparencia y la confidencialidad, especialmente en el caso de datos sensibles. Estos usuarios deben asegurarse de que los datos sean precisos, completos y detallados, ya que la calidad de la información es crucial para que los sistemas de *Machine Learning* se entrenen correctamente y generen resultados confiables. Un manejo cuidadoso y riguroso de los datos no solo reduce la probabilidad de errores en los modelos, sino que también permite que los resultados sean más claros y transparentes, facilitando la toma de decisiones basada en evidencia y fortaleciendo la confianza en el uso de estas tecnologías dentro de la organización.

6. ¿Podría mencionar un caso exitoso donde ML haya generado impacto en finanzas de PYMEs o empresas similares?

En mi experiencia laboral actual, estuve involucrado en la prevención de fraude dentro de la empresa, utilizando modelos de *Machine Learning* implementados en plataformas de Microsoft. Esta tecnología nos permitió automatizar la supervisión de interacciones entre los colaboradores y los clientes, identificando términos, palabras o frases que comúnmente estaban asociados con comportamientos de riesgo. De esta manera, el sistema se volvió predictivo, facilitando la detección de malas prácticas que podían generar pérdida de cercanía con el cliente, fuga de información o pérdidas financieras. Gracias a este enfoque, fue posible analizar con mayor detalle la información sensible y fortalecer las medidas de prevención de fraude, optimizando tanto la seguridad como la eficiencia de los procesos internos.

7. En su opinión, ¿cuáles son los principales desafíos éticos o de gobernanza de datos que deberían considerarse al aplicar Machine Learning?

Los desafíos éticos en Machine Learning surgen principalmente de las personas que entrenan y automatizan los modelos. Si quienes participan en este proceso poseen sesgos o prejuicios, estos pueden transferirse a modelos que no estén debidamente regularizados o estandarizados, comprometiendo la precisión y la integridad de los datos fundamentales para el desarrollo de los sistemas. Además, el desafío ético no recae únicamente en un individuo, sino también en los equipos responsables de la gobernanza de los modelos, ya que cada área de la organización contribuye de manera significativa al entrenamiento y supervisión de los algoritmos. Por tanto, garantizar la equidad, la transparencia y la responsabilidad en Machine

Learning requiere un esfuerzo colaborativo y consciente por parte de todas las personas involucradas en el desarrollo y mantenimiento de estos sistemas.

Consentimiento Informado

Yo, Diego Mora declaro que he sido informado/a sobre el propósito de la entrevista, la duración aproximada y el uso académico de la información recolectada. Comprendo que mi participación es voluntaria y que puedo retirarme en cualquier momento sin consecuencias. Autorizo la grabación de la entrevista con fines estrictamente investigativos, asegurando el anonimato y confidencialidad de mis respuestas.

Firma del participante: *Diego Mora*

Fecha: 28 de octubre de 2025

Grupo: León, Hernandez, Morales

Título del Proyecto: Analítica Predictiva para la Inteligencia Financiera de PYMEs en Colombia.

Calificación Final: 19.5 / 20

1. Informe Ejecutivo

Un informe excelente y de gran profundidad académica. El equipo ejecutó su metodología cualitativa con un rigor excepcional. El Análisis de Resultados (Sección 7) es un modelo de cómo presentar hallazgos cualitativos, organizando la información de las entrevistas y el análisis documental por cada objetivo específico y logrando una triangulación efectiva.

La Discusión (Sección 8) es el punto más fuerte del informe: conecta de manera brillante los hallazgos (ej. barreras culturales) con los modelos teóricos (TAM, TOE, Z-score). Las Conclusiones (Sección 9) proponen los lineamientos estratégicos (el entregable final), cumpliendo el objetivo general y utilizando las 5+ referencias requeridas para la discusión.

2. Retroalimentación Accionable

- **Extensión:** El informe final tiene 52 páginas. Si bien la profundidad del análisis cualitativo lo justifica, excede significativamente el límite máximo de 45 páginas de la guía. Un esfuerzo de síntesis en el Marco Teórico habría sido ideal.

- **Consistencia de Referencias:** Se corrigieron la mayoría de las inconsistencias en las referencias, aunque una revisión final de formato APA siempre es útil en documentos de esta densidad.
- **3. Sugerencias para la Práctica Profesional**
- Los "Lineamientos Estratégicos" (Sección 9.1) son un producto de alto valor. Este capítulo podría adaptarse como un *white paper* o una guía práctica para gremios empresariales (como ACOPI o Cámaras de Comercio) interesados en la transformación digital de sus afiliados.
- La combinación de perfiles (Gerencia de Proyectos y Machine Learning) es una ventaja competitiva clave; sigan explorando esa intersección.