



Escuela de Posgrados

**“ Sistema de predicción de las tasas de Interés Bancario Corriente y de usura en Colombia: Oportunidades para las Entidades Bancarias vigiladas por la Superintendencia Financiera de Colombia - SPF ”**

Ana María García Pineda

Elizabeth Sierra Duarte

Nelson Yesid Monsalve

Trabajo de Grado presentado como requisito para optar al título de:

Especialista en Big Data e Inteligencia de Negocios

Asesor: Ingrid Durley Torres Pardo

Título de Posgrado

Universidad Católica Luis Amigó

Facultad de Ingenierías y

Arquitectura

Especialización en Big Data e Inteligencia de Negocios

Medellín, Colombia

2025

## Tabla de Contenido

Lista de figuras .....	3
Lista de tablas.....	4
1. Introducción .....	5
2. Planteamiento del Problema .....	6
3. Justificación .....	7
4. Marco de Referencias .....	8
5. Antecedentes.....	10
6. Objetivos.....	14
6.1 Objetivo General.....	14
6.2 Objetivos Específicos .....	14
7. Viabilidad .....	15
8. Metodología .....	17
9. Resultados.....	20
9.1 Comprensión del negocio.....	22
9.2 Comprensión de los datos.....	23
9.3 Preparación de los datos.....	25
9.4 Modelado .....	31
9.5 Evaluación y Despliegue .....	35
10. Conclusiones .....	36
11. Referencias.....	37

## Lista de figuras

Figura 1 Flujograma .....	11
Figura 2 Metodología CRISP-DM .....	17
Figura 3 Metodología CRISP-DM .....	20
Figura 4 Orden de carpetas .....	22
Figura 5 Variables necesarias.....	24
Figura 6 ETL parte 1.....	26
Figura 7 ETL parte 2.....	27
Figura 8 Salida ETL.....	27
Figura 9 Agrupador mes.....	28
Figura 10 Salida agrupada por mes.....	28
Figura 11 Concatenación por mes.....	29
Figura 12 Salida concatenación.....	29
Figura 13 Dataset completo .....	30
Figura 14 Selección modo.....	31
Figura 15 Modelo LSTM.....	32
Figura 16 Anexo de tasas por mes .....	32
Figura 17 Evolución y predicción de tasas .....	33
Figura 18 Evolución de pérdida en entrenamiento .....	34
Figura 19 Métricas de rendimiento.....	35

**Lista de tablas**

Tabla 1 Objetivos asociados a las fases.....21

## **1. Introducción**

La tasa de interés Bancario Corriente y la tasa de Usura en Colombia son indicadores claves que afectan tanto a la economía en general como a las decisiones financieras de las entidades bancarias vigiladas por La Superintendencia Financiera. Sin embargo, esta tasa solo se determina el último día hábil de cada mes, lo que dificulta que las instituciones financieras puedan con anticipación ajustar sus propias tasas de interés de manera anticipada ya que dependen de la Tasa de Interés Bancario Corriente y la Tasa de Usura, que son establecidas por la Superintendencia Financiera. Esta incertidumbre puede resultar en decisiones poco óptimas, afectando la rentabilidad de las entidades y la disponibilidad de condiciones crediticias adecuadas para los consumidores financieros. La falta de modelos predictivos efectivos puede llevar a un desajuste entre las expectativas del mercado y las acciones de los bancos, generando tensiones en la estabilidad financiera.

El objetivo general de esta investigación es desarrollar un modelo predictivo orientado a inferir la tasa de interés corriente y la tasa de Usura en Colombia, que permita a las entidades bancarias realizar cambios y ajustar sus estrategias financieras de manera oportuna. A través de la identificación y análisis de los factores económicos, políticos y sociales que influyen en la determinación de esta tasa, se busca crear un marco metodológico que integre técnicas de modelado estadístico y de aprendizaje automático. Este enfoque no solo pretende obtener la precisión de las predicciones, sino también ofrecer a las instituciones financieras herramientas que guíen su toma de decisiones, fomentando la estabilidad económica y el acceso equitativo al crédito para los consumidores.

## **2. Planteamiento del Problema**

En Colombia, la determinación mensual de la Tasa de Interés Bancario Corriente y la Tasa de Usura por parte de la Superintendencia Financiera representa un desafío para las entidades financieras que necesitan tomar decisiones estratégicas de manera anticipada. Al ser fijadas únicamente el último día hábil de cada mes, estas tasas introducen un alto nivel de incertidumbre en la planificación financiera y operativa de los bancos. Esta situación limita su capacidad para ajustar con tiempo sus productos crediticios, políticas de riesgo y estructuras de costos, lo cual puede traducirse en decisiones subóptimas que afectan directamente su rentabilidad y competitividad. La imposibilidad de prever con exactitud los cambios en estas tasas también repercute en los consumidores financieros, quienes enfrentan condiciones crediticias volátiles y poco predecibles, reduciendo el acceso al crédito y afectando la confianza en el sistema financiero.

A pesar de la disponibilidad de grandes volúmenes de datos económicos, sociales y políticos que podrían aportar señales sobre el comportamiento de estas tasas, actualmente no existen modelos predictivos ampliamente adoptados ni metodologías sistemáticas que permitan anticipar su valor con un grado de certeza aceptable. Por tanto, se evidencia la necesidad urgente de un modelo predictivo robusto que no solo integre variables clave del entorno macroeconómico y financiero, sino que también utilice técnicas avanzadas de modelado estadístico y aprendizaje automático para ofrecer pronósticos precisos. Abordar esta necesidad permitiría mitigar los riesgos asociados a la incertidumbre regulatoria, mejorar la estabilidad del sistema financiero y facilitar un entorno crediticio más transparente y justo para los consumidores.

### **3. Justificación**

La capacidad de anticipar las condiciones del mercado financiero es esencial para la sostenibilidad y el crecimiento económico de un país. En un contexto donde las fluctuaciones pueden afectar tanto a las entidades financieras como a los consumidores, es imperativo comprender los factores que determinan las tasas de interés.

La tasa de interés bancario corriente es el costo del dinero que las entidades financieras cobran a sus clientes por los préstamos otorgados y con base en esta se calcula la tasa de usura es el límite máximo que pueden cobrar las entidades financieras por el dinero prestado y que corresponde al 1.5 del interés bancario corriente.

Continuando con lo anterior, la predicción de la tasa de interés corriente y de la tasa de usura en Colombia es fundamental debido a su impacto significativo en la economía del país y en la operativa de las entidades bancarias vigiladas por la Superintendencia Financiera de Colombia. En un contexto donde las decisiones financieras deben adaptarse a condiciones cambiantes del mercado, la capacidad de anticipar la evolución de esta tasa se convierte en una herramienta de vital importancia. Un modelo que permita predecir la tasa de interés ayudará a las entidades a ajustar sus tasas de crédito y ahorro de manera más eficiente, lo que no solo mejoraría su competitividad y rentabilidad, sino que también contribuiría a la estabilidad del sistema financiero. Asimismo, al ofrecer condiciones más alineadas con el comportamiento del mercado, se beneficiaría a los consumidores financieros, facilitando un acceso más responsable y equitativo al crédito.

Por estas razones, la investigación en este tema es de suma importancia para una oferta financiera más dinámica y adaptativa. Finalmente, la predicción de las tasas no solo es un ejercicio académico, sino una necesidad práctica que puede transformar la manera en que operan tanto las entidades financieras como los consumidores. Al abordar esta investigación, se establece un camino hacia un sistema financiero más robusto, capaz de responder eficazmente a las demandas del mercado y a las necesidades de todos los actores involucrados

#### 4. Marco de Referencias

**Big Data:** volúmenes de datos disponibles en diversos grados de complejidad, generados a diferentes velocidades y diversos grados de ambigüedad, que no pueden procesarse utilizando tecnologías tradicionales, métodos de procesamiento, algoritmos o cualquier solución comercial lista para usar (Krishnan, 2013).

**Tasa de Interés:** La tasa de interés es un porcentaje de la operación que se realiza. Es un porcentaje que se traduce en un monto de dinero, mediante el cual se paga por el uso del dinero. (Comisión para el Mercado Financiero, 2025).

**Tasa de Interés Corriente:** Es la tasa efectiva anual que en promedio cobran las entidades sobre los nuevos créditos. Es una tasa de referencia del mercado. Se ajusta frecuentemente de acuerdo a las condiciones del mercado y la política monetaria. (SPF, 2010).

**Tasa de Usura:** La tasa de usura representa el valor máximo de los intereses remuneratorio o moratorio que puede cobrar un organismo a los agentes de la economía y se construye como 1.5 veces el interés bancario corriente por modalidad de crédito. (Banco de la República de Colombia, s/f).

**Crédito de consumo:** Es el constituido por las operaciones activas de crédito realizadas con personas naturales para financiar la adquisición de bienes de consumo o el pago de servicios para fines no comerciales o empresariales, incluyendo las efectuadas por medio de sistemas de tarjetas de crédito, en ambos casos, independientemente de su monto. (SPF, 2010).

**Crédito ordinario:** es el constituido por las operaciones activas de crédito realizadas con personas naturales o jurídicas para el desarrollo de cualquier actividad económica (SPF, 2010).

**Redes Neuronales:** Una red neuronal es un programa, o modelo, de machine learning que toma decisiones de forma similar al cerebro humano, utilizando procesos que imitan la forma en que las neuronas biológicas trabajan juntas para identificar fenómenos, sopesar opciones y llegar a conclusiones. (IBM, 2024).

**Modelos de Series Temporales:** Una serie temporal es un conjunto de observaciones que se obtiene midiendo una variable única de manera regular a lo largo de un período de tiempo y contiene métodos estadísticos que analizan datos a lo largo del tiempo para identificar patrones y prever futuros comportamientos.(IBM, 2024).

**Predicción Financiera:** Proceso de estimar futuros resultados financieros basándose en análisis históricos y modelos estadísticos o algoritmos de aprendizaje automático. Es esencial para la toma de decisiones en el ámbito bancario y financiero. (Teruel S, S/F).

**Microcrédito:** Los microcréditos son un tipo de préstamo rápido y de pequeña cuantía económica para financiar necesidades básicas. Están dirigidos principalmente a colectivos vulnerables que tienen dificultades para conseguir préstamos tradicionales. (MicroBank, 2023).

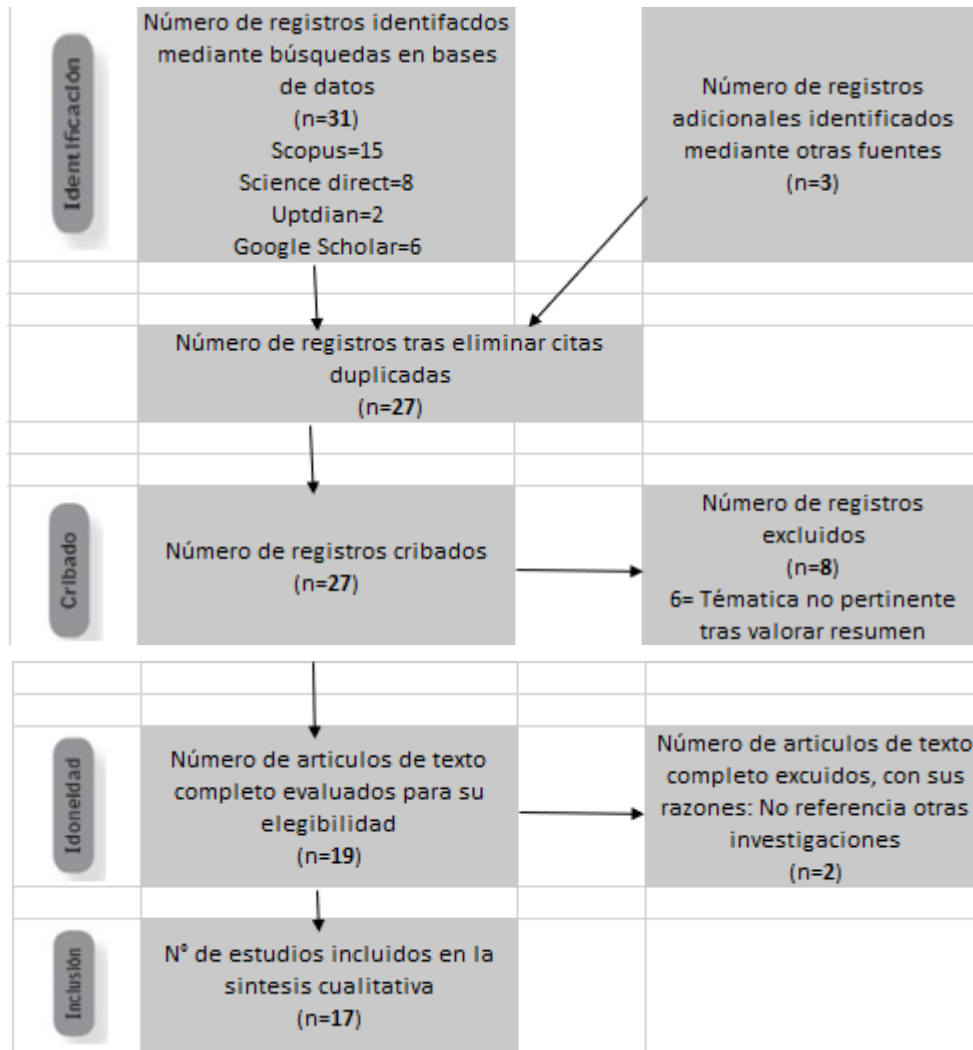
## 5. Antecedentes

La metodología RSL proporcionó un marco riguroso y estructurado para la recopilación, análisis y síntesis de la información relevante disponible en la literatura sobre este tema en específico. Para la búsqueda, se definieron tres preguntas de investigación que ayudaron a orientar el proceso y centrarse en los temas más relevantes para este trabajo.

- ¿Cómo puede la implementación de modelos predictivos de la tasa de interés corriente mejorar la toma de decisiones estratégicas de las entidades bancarias en el contexto colombiano?
- ¿Qué papel juegan los indicadores macroeconómicos, como el PIB, la tasa de desempleo y la balanza de pagos, en la predicción de la tasa de interés corriente en Colombia?
- ¿Qué técnicas de análisis de datos son más efectivas para identificar patrones históricos en la tasa de interés corriente, y cómo pueden estos patrones informarles a las entidades bancarias sobre futuras tendencias?

Además, se elaboró un flujograma que muestra de forma visual cómo se desarrolló el proceso de revisión sistemática. En este diagrama se presentan las diferentes etapas del análisis, indicando cuántos registros fueron encontrados, seleccionados y descartados, junto con las razones por las cuales algunos fueron excluidos.

Figura 1 Flujograma



El tema de la predicción de la tasa de interés corriente en el ámbito bancario colombiano ha sido abordado desde diversas perspectivas, impulsado principalmente por la creciente disponibilidad de datos y los avances en el área de analítica. En el ámbito de la transformación digital, estudios han revelado el potencial del Big Data y la analítica predictiva para revolucionar la toma de decisiones empresariales. La capacidad de anticipar tendencias mediante el análisis de datos históricos se ha identificado como un factor clave para la formulación de estrategias informadas. La integración de modelos automatizados de IA, como lo señala Altamirano Pérez (2025), ha demostrado mejorar la eficiencia y precisión en el análisis de datos financieros, reduciendo cierta

dependencia de recursos humanos y agilizando los procesos en la toma de decisiones.

En una segunda perspectiva, desde el modelado y la inteligencia artificial, las investigaciones realizadas se han centrado en la aplicación de técnicas avanzadas para la extracción de información valiosa de datos financieros complejos. En este sentido, las redes LSTM han evidenciado una notable capacidad para el análisis y la predicción en este dominio. Estos métodos permiten a las entidades bancarias procesar grandes volúmenes de información de datos históricos de manera más efectiva, identificando patrones que se consideran difíciles de discernir mediante métodos tradicionales.

Siguiendo con lo anterior, en el ámbito macroeconómico, diversos estudios han examinado la influencia de indicadores como el PIB, la tasa de desempleo y la balanza de pagos en la dinámica de las tasas de interés en Colombia. Investigaciones como la de Vásquez (2014) resaltan la importancia de estos indicadores como señales de la salud económica y de las posibles acciones del Banco de la República en materia de política monetaria. Acuña Trujillo (2018) va más allá al sugerir que la inclusión de estas variables macroeconómicas mejora la precisión de las proyecciones de las tasas de interés. Por otro lado, el análisis del BIS (s.f.) hace mención de cómo la apertura económica puede influir en la efectividad de la política monetaria, enfatizando la relevancia de la balanza de pagos y el PIB en la determinación de la tasa de interés óptima para economías como la colombiana.

En los hallazgos más importantes, se encontró que los informes del Banco de la República, como el de octubre de 2024, también vinculan la evolución de la inflación con las decisiones de política monetaria que afectan las tasas de interés. El estudio de 2016 en Ecos de Economía confirma la transmisión significativa de las tasas de política en las tasas del sistema financiero en un horizonte de tiempo específico.

Para finalizar, tenemos un enfoque en el ámbito de las series de tiempo. Allí se encontró que se han explorado diversas metodologías y técnicas para identificar patrones históricos que alteran la tasa de interés corriente. Métodos como el filtro de Hodrick-Prescott (Schüler, 2024) y los modelos

ARIMA (Menéndez-García et al., 2024) son utilizados para descomponer series temporales y detectar patrones subyacentes. Técnicas como las Redes Neuronales Recurrentes (Bhambu et al., 2024) y los modelos GARCH (Tian & Hamori, 2015) han demostrado su capacidad para modelar la complejidad y la volatilidad de los datos a nivel financiero. Con estos antecedentes, podemos concluir que la aplicación de estas técnicas proporciona a las entidades bancarias la capacidad de anticipar tendencias basadas en una evidencia histórica.

## **6. Objetivos**

### **6.1 Objetivo General**

Desarrollar un modelo predictivo que permita inferir la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia, integrando técnicas de modelado estadístico y aprendizaje automático, con el fin de apoyar a las entidades financieras en la toma de decisiones estratégicas que fomenten la estabilidad económica y el acceso oportuno al crédito.

### **6.2 Objetivos Específicos**

- Realizar un proceso de ingeniería de requisitos efectivo, basado en la metodología CRISP-DM, que permita garantizar el entendimiento integral del modelo de negocio y asegurar el desarrollo exitoso del proyecto.
- Identificar y analizar los factores económicos, y sociales más relevantes que influyen en la fijación de la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia.
- Evaluar y seleccionar las técnicas de modelado estadístico y de aprendizaje automático más adecuadas para la predicción de dichas tasas, con base en criterios de precisión y aplicabilidad en el contexto financiero colombiano.
- Desarrollar e implementar el modelo predictivo propuesto, validando su desempeño mediante métricas estadísticas y simulaciones que permita a las entidades bancarias realizar cambios y ajustar sus estrategias financieras de manera oportuna.

## 7. Viabilidad


- Disponibilidad de recursos: El proyecto cuenta con una alta disponibilidad de recursos tanto en términos de datos como de herramientas tecnológicas. En Colombia, entidades como el Banco de la República, el DANE, la Superintendencia Financiera y otras organizaciones oficiales publican información económica de forma periódica y accesible, lo que facilita la recolección de datos históricos relevantes para el modelado predictivo. Además, se dispone de plataformas computacionales de uso libre como Python y R, que ofrecen librerías especializadas para análisis de datos, estadística y aprendizaje automático, lo cual permite desarrollar modelos sin necesidad de adquirir software licenciado. También se cuenta con talento humano en áreas como ciencia de datos, estadística y finanzas, lo cual fortalece la factibilidad técnica del proyecto.
- Alcance: El alcance del proyecto está centrado en el desarrollo de un modelo predictivo para inferir la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia, dirigido principalmente a las entidades financieras reguladas por la Superintendencia Financiera. No obstante, el modelo podría ampliarse en el futuro a otros sectores del sistema financiero o incluso adaptarse a otros países con contextos regulatorios similares. A nivel temporal, el proyecto contempla la construcción, validación y evaluación de un modelo funcional en una primera fase, para luego analizar su aplicabilidad en entornos reales de toma de decisiones financieras.
- Implicaciones: La implementación de este modelo tiene implicaciones significativas para el sistema financiero. Por un lado, proporciona a las entidades bancarias una herramienta útil para anticipar las decisiones regulatorias en cuanto a tasas de interés, lo que les permite tomar decisiones estratégicas más acertadas. Por otro lado, fomenta una cultura de análisis predictivo basada en datos, lo que puede generar un cambio en la forma en que las entidades enfrentan la volatilidad del entorno económico. Además, la seguridad de la información de

los beneficiarios es crítica. Implica implementar medidas de seguridad sólidas para proteger los datos personales y sensibles de los usuarios.

- Consecuencias: Entre las consecuencias más importantes se destaca la posibilidad de mejorar la estabilidad financiera del país al reducir la incertidumbre en la fijación de tasas de interés clave. Esto puede traducirse en una mayor eficiencia en la gestión de riesgos por parte de los bancos y una mejora en las condiciones de acceso al crédito para los consumidores. No obstante, también se deben considerar riesgos asociados al uso indebido de las predicciones, por lo que será necesario establecer límites éticos y normativos claros sobre su uso, así como promover la transparencia en su implementación.

## 8. Metodología

Esta investigación se desarrolló siguiendo la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining), un proceso iterativo y cíclico ampliamente utilizado en proyectos de análisis de datos y modelado predictivo.



*Figura 2 Metodología CRISP-DM*

Para la aplicación de esta metodología, se tienen en cuenta seis fases que dependen entre sí y en cada fase se encuentran los siguientes elementos:

### **Fase 1:** Entendimiento del Negocio

En esta fase inicial, el enfoque principal será la clarificación exhaustiva de los objetivos de la investigación y para ello nos basamos en los criterios de objetivos de la técnica SMART. Se realizará un análisis profundo del problema de la predicción tardía de la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia, detallando las implicaciones que esta tiene para las entidades bancarias y los consumidores finales.

## **Fase 2:** Entendimiento de los Datos

En esta segunda fase, se centra en la recopilación, descripción y exploración exhaustiva de los datos relevantes para la construcción del modelo predictivo. La recolección de los datos es muy significativa, ya que se debe prestar atención al detalle de la data para que no quede ningún valor o variable de interés por fuera del análisis. Por otro lado, es en esta fase en donde se identifican las fuentes oficiales de donde se tomarán los datos y los indicadores macroeconómicos clave.

## **Fase 3.** Preparación de los Datos

En la tercera fase, se analiza el proceso que se va a realizar para la limpieza de la base de datos, se transformaran y seleccionarán las variables que son indispensables para nuestro modelo predictivo. También, se abordaron problemas de calidad de la data y se crearán las variables nuevas relevantes para posteriormente realizar el modelado.

## **Fase 4.** Modelado

En esta fase, por medio del modelado se seleccionan las técnicas y se aplicarán los algoritmos para la construcción del modelo predictivo. Se calibrarán los parámetros para optimizar su rendimiento y se compararán los resultados obtenidos para identificar el modelo más adecuado para la predicción de la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia.

## **Fase 5.** Evaluación

Después de haber construido y ajustado el modelo, se realizará una evaluación de su rendimiento utilizando métricas predefinidas y considerando su capacidad para cumplir con los objetivos del negocio establecidos en la primera fase. Se determina si el modelo elegido cumple satisfactoriamente con las predicciones precisas.

## **Fase 6.** Despliegue

En esta última fase de la metodología CRISP-DM, es donde se determina la estrategia para implementar el modelo seleccionado en un entorno práctico para mantener el monitoreo de las

predicciones a lo largo del tiempo. Finalmente, y no menos importante, se documentará el modelo y se definirán los procedimientos para su mantenimiento y actualización; garantizando así la usabilidad de este a través del tiempo.

## 9. Resultados

En este capítulo se presenta el desarrollo de la red neuronal LSTM creada para cumplir con los objetivos específicos del proyecto. El proceso se aborda siguiendo distintas etapas:

Primero, la comprensión del negocio, donde se identifican las necesidades y metas que orientan el análisis, asegurando que las soluciones propuestas respondan a un propósito claro. Luego, la comprensión de los datos, que consiste en explorar, analizar y conocer la información disponible para determinar su calidad, relevancia y posibles limitaciones. Posteriormente, se aborda la preparación de los datos, fase en la que se limpian, transforman y organizan los datos para que puedan ser utilizados adecuadamente en los modelos. A continuación, el modelado, donde se aplican técnicas analíticas o de aprendizaje automático para generar resultados que permitan responder a los objetivos planteados. Después se realiza la evaluación, en la que se analizan los resultados obtenidos a partir de métricas específicas para medir el desempeño y la efectividad de los modelos. Finalmente, se lleva a cabo el despliegue, etapa en la que se implementa la solución desarrollada para su uso práctico, facilitando la toma de decisiones

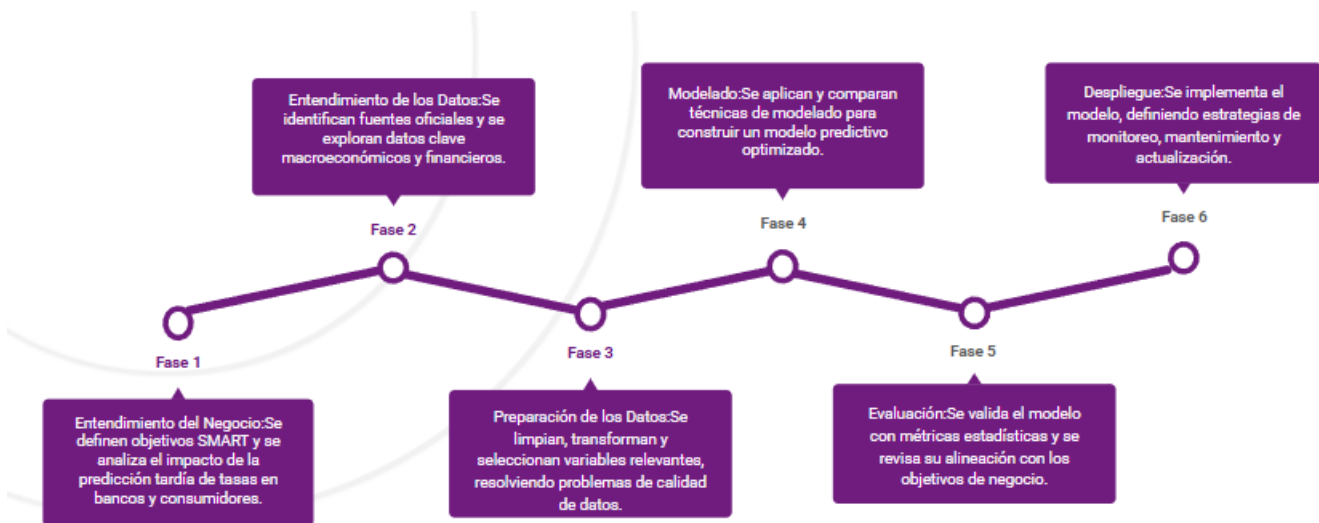


Figura 3 Metodología CRISP-DM

<b>Objetivo Específico</b>	<b>Fase CRISP-DM Asociada</b>
Realizar un proceso de ingeniería de requisitos efectivo, basado en la metodología CRISP-DM, que permita garantizar el entendimiento integral del modelo de negocio y asegurar el desarrollo exitoso del proyecto.	Fase 1 – Entendimiento del Negocio
Identificar y analizar los factores económicos y sociales más relevantes que influyen en la fijación de la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia.	Fase 2 – Entendimiento de los Datos
Evaluar y seleccionar las técnicas de modelado estadístico y de aprendizaje automático más adecuadas para la predicción de dichas tasas, con base en criterios de precisión y aplicabilidad en el contexto financiero colombiano.	Fase 4 – Modelado
Desarrollar e implementar el modelo predictivo propuesto, validando su desempeño mediante métricas estadísticas y simulaciones que permita a las entidades bancarias realizar cambios y ajustar sus estrategias financieras de manera oportuna.	Fases 5 y 6 – Evaluación y Despliegue

*Tabla 1 Objetivos asociados a las fases*


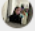






## 9.1 Comprensión del negocio

El objetivo principal del proyecto es analizar y modelar el comportamiento de las tasas de interés en Colombia, con base en información histórica publicada en el Portal de Datos Abiertos de la Superintendencia Financiera. El objetivo es proporcionar una base de datos limpia y estructurada que permita predecir las tasas futuras mediante métodos de aprendizaje automático, específicamente redes neuronales LSTM, considerando la naturaleza de las series temporales de los datos.

Para alcanzar este objetivo general, se plantearon los siguientes objetivos específicos:

- **Identificar las variables relevantes** para el análisis de las tasas de interés, descartando aquellas que no aportan al modelo.
- **Construir un proceso ETL sencillo** que permita transformar la base original de 23 columnas en una versión reducida y optimizada, con solo las variables necesarias para la predicción.
- **Definir un marco temporal inicial de trabajo** con datos comprendidos desde marzo de 2025, que servirá como dataset base para la experimentación inicial.

En esta fase se determinó que la predicción de las tasas de interés resulta fundamental, ya que permite identificar las tendencias del sistema financiero colombiano y comprender el comportamiento del costo del crédito en sus diferentes modalidades y segmentos de mercado.

 00.Inputs	 yo	3 sept	—	⋮
 01.First_Outputs	 yo	3 sept	—	⋮
 02.Second_Outputs	 yo	5 sept	—	⋮
 03.Outputs	 yo	5 sept	—	⋮

*Figura 4 Orden de carpetas*

## 9.2 Comprensión de los datos

La fuente de información corresponde al dataset:

[Tasas de interés activas por tipo de crédito – Histórico \(Superintendencia Financiera\)](#).

El dataset es publicado por la Superintendencia Financiera de Colombia con una periodicidad semanal, y cuenta con una cobertura nacional que permite distintos niveles de segmentación, incluyendo tipo de crédito, tipo de entidad, tamaño de empresa, sexo, grupo étnico y municipio, entre otros. En total, contiene más de 54,1 millones de registros con 23 variables iniciales que incluyen datos categóricos, numéricos y de fecha, lo que lo convierte en una fuente amplia y diversa de información.

La información refleja la evolución de las tasas de interés promedio ponderadas, junto con el monto y número de créditos desembolsados en diferentes modalidades, tales como consumo, vivienda, crédito comercial y productivo. Este conjunto de datos permite realizar un análisis detallado de la dinámica del crédito en Colombia, ofreciendo insumos para estudios financieros, de inclusión económica y de comportamiento del sistema crediticio en distintos sectores y poblaciones.

Durante esta fase se identificaron varios hallazgos importantes. En primer lugar, se determinó que no todas las variables disponibles aportaban valor al objetivo de predicción. Además, se evidenció la ausencia de las columnas correspondientes a la Tasa de interés cambiario corriente y a la Tasa de usura, las cuales fueron posteriormente incorporadas al conjunto de datos. Asimismo, se analizó la estructura y tipología de cada variable, lo que permitió una mejor comprensión de la información. Finalmente, se seleccionaron aquellas variables que representaban de manera más precisa el comportamiento de las tasas de interés en función del tipo de producto y del monto desembolsado.

Nombre de la columna	Descripción	Tipo de dato	Ejm
Nombre_Tipo_Entidad	Nombre de la entidad	Texto	BC-ESTABLECIMIENTO BANCARIO
Fecha_Corte	Fecha en la que se realizó el corte	Marca de tiempo variable	14/03/2025
Producto de crédito	El producto para cual adquirió el crédito	Texto	Tarjeta de crédito para ingresos hasta 2 SMMLV
Tasa_Efectiva_promedio_ponderada	Promedio de tasas de interés, donde cada una es ponderada por el monto que representa	Número	24,66
Montos_desembolsados	La cantidad de dinero entregado por el crédito	Número	5.765.236,
Numero_de_creditos_desembolsados	Cantidad de créditos que se dieron	Número	14
Tipo_de_tasa	Categoría del tipo de tasa utilizada para cada crédito	Texto	FS

*Figura 5 Variables necesarias*

### 9.3 Preparación de los datos

En esta fase se construyó un proceso ETL sencillo, cuyo propósito fue depurar y transformar los datos crudos para obtener una versión lista para el modelamiento.

#### Extracción:

- Se descargó el dataset completo desde la fuente oficial.
- Se definió un histórico inicial desde julio de 2022, para tener amplitud de series.

#### Transformación:

- Se analizaron las 23 columnas originales y se redujeron a 8, manteniendo solo las necesarias para el análisis y predicción.
- Se creó y agregó la columna faltante: Tasa de interés cambiario corriente y tasa de usura.
- Se verificó la calidad de datos, identificando tipos de datos correctos (fechas, números, texto).
- Se estandarizó el formato de variables temporales y numéricas.
- Se normalizó la columna de fecha corte, para que tuviera el mismo formato

#### Carga:

- Se consolidó un dataset limpio con 8 columnas seleccionadas.
- Se dejó listo un subconjunto de trabajo con 6 meses de datos, desde marzo de 2025.

El siguiente código (Ver figura 6) pone en práctica esta fase, llevando a cabo un proceso ETL sencillo para limpiar y organizar la información antes del modelamiento. Su función principal es tomar los archivos originales desde Google Drive, seleccionar solo las columnas necesarias y eliminar errores comunes como espacios en los nombres o valores vacíos, asegurando que los datos estén uniformes y listos para ser analizados.

Además, el script automatiza tareas que normalmente se harían de forma manual, como revisar la calidad de los datos, contar los valores faltantes y guardar versiones limpias de los archivos en una carpeta de salida. De esta manera, el resultado final es un conjunto de datos más confiable y estructurado (Ver figura 7) coherente con el proceso de transformación que habíamos descrito previamente y listo para ser utilizado en las próximas etapas del proyecto.

```
import pandas as pd
import os
from google.colab import drive

# 2. Definir rutas
input_folder = '/content/drive/MyDrive/Especialización/Semestre 2/Trabajo de grado 2/Codigo/00.Inputs'
output1_folder = '/content/drive/MyDrive/Especialización/Semestre 2/Trabajo de grado 2/Codigo/01.First_Outputs'

# 3. Columnas que quieres conservar
columnas_requeridas = [
    "Nombre_Tipo_Entidad",
    "Fecha_Corte",
    "Producto de crédito",
    "Tasa_efectiva_promedio_ponderada",
    "Montos_desembolsados",
    "Numero_de_creditos_desembolsados",
    "Tipo_de_Tasa"
]

# 4. Procesar cada archivo
archivos = [f for f in os.listdir(input_folder) if f.endswith('.xlsx')]
print(f"Archivos encontrados: {len(archivos)}")

total_vacios = 0 # contador global que inicio en 0 para saber al finalizar cuantos vacios encuentro

for archivo in archivos:
    ruta = os.path.join(input_folder, archivo)
    df = pd.read_excel(ruta)
```

Figura 6 ETL parte 1

```

for archivo in archivos:
    ruta = os.path.join(input_folder, archivo)
    df = pd.read_excel(ruta)

    # Limpiar espacios en nombres de columnas
    df.columns = df.columns.str.strip()

    # Filtrar solo las columnas requeridas
    df = df[[col for col in columnas_requeridas if col in df.columns]]

    # Eliminar espacios en cada valor tipo string
    df = df.applymap(lambda x: x.strip() if isinstance(x, str) else x)

    # Contar vacíos por archivo
    vacios = df.isna().sum().sum()
    total_vacios += vacios
    print(f"Archivo: {archivo} → Vacíos encontrados: {vacios}")

    # Guardar archivo limpio en outputs
    salida = os.path.join(output1_folder, archivo)
    df.to_excel(salida, index=False)

# 5. Mostrar cuántos archivos quedaron en outputs y total de vacíos
archivos_salida = [f for f in os.listdir(output1_folder) if f.endswith('.xlsx')]
print(f"\n Archivos procesados y guardados en 'outputs': {len(archivos_salida)}")
print(f"Total de valores vacíos encontrados en todos los archivos: {total_vacios}")

```

*Figura 7 ETL parte 2*

<pre> Archivos procesados y guardados en 'outputs': 24 Total de valores vacíos encontrados en todos los archivos: 0 </pre>
--

*Figura 8 Salida ETL*

Como el histórico de información que descargamos directamente de la fuente oficial de la superintendencia financiera estaba compuesto por muchos archivos separados, fue necesario hacer un paso adicional en el proceso ETL para simplificar y organizar los datos. Este código (Ver figura 9) se encarga de agrupar todos los archivos correspondientes a cada mes y unirlos en un solo archivo mensual, desde marzo hasta agosto de 2025. Así se obtiene una base más ordenada y fácil de manejar.

```

# 7. Listar archivos de entrada
archivos = [f for f in os.listdir(input_folder) if f.endswith('.xlsx')]
print(f"Archivos encontrados: {len(archivos)}")

# 8. Agrupar archivos por mes
grupos = {}
for archivo in archivos:
    mes = archivo.split()[0] # Primer palabra del nombre -> Mes
    grupos.setdefault(mes, []).append(archivo)

# 9. Procesar cada grupo de mes y guardar resumen
resumen = []

for mes, lista_archivos in grupos.items():
    dfs = []
    for archivo in sorted(lista_archivos): # Ordenar archivos del mes
        ruta = os.path.join(input_folder, archivo)
        df = pd.read_excel(ruta)
        dfs.append(df)

# Concatenar todos los archivos del mes
df_final = pd.concat(dfs, ignore_index=True)

# Nombre del archivo de salida
nombre_salida = f"{mes}_2025.csv"
ruta_salida = os.path.join(output_folder, nombre_salida)

```

*Figura 9 Agrupador mes*

```

📁 Archivos encontrados: 24
  Mayo_2025.csv creado con 2767284 registros
  Marzo_2025.csv creado con 2104814 registros
  Junio_2025.csv creado con 2438115 registros
  Julio_2025.csv creado con 2465777 registros
  Agosto_2025.csv creado con 1860252 registros
  Abril_2025.csv creado con 2104747 registros

📊 Resumen de archivos creados:
  Mes  Registros
0  Mayo  2767284
1  Marzo  2104814
2  Junio  2438115
3  Julio  2465777
4  Agosto  1860252
5  Abril  2104747

```

*Figura 10 Salida agrupada por mes*

Debido al tamaño y la cantidad de información contenida en los archivos originales, no fue posible realizar todo el proceso de consolidación en un solo paso, ya que los archivos resultaban demasiado pesados y Google Colab tendía a detenerse o pegarse durante la ejecución. Por eso, se optó por dividir el procedimiento en etapas: primero se unificaron los archivos por mes y luego, con este código (Ver figura 11), se integraron todos los meses en un único archivo consolidado correspondiente al año 2025. Esta estrategia nos permitió manejar mejor los recursos del entorno, evitando errores y asegurando que el dataset final quedará completo y limpio.

```
orden_meses = ["Marzo", "Abril", "Mayo", "Junio", "Julio", "Agosto"]

# 13. Leer, concatenar y guardar
dfs = []
resumen = []

for mes in orden_meses:
    archivo_csv = os.path.join(input_folder, f"{mes}_2025.csv")
    if os.path.exists(archivo_csv):
        df = pd.read_csv(archivo_csv)
        dfs.append(df)

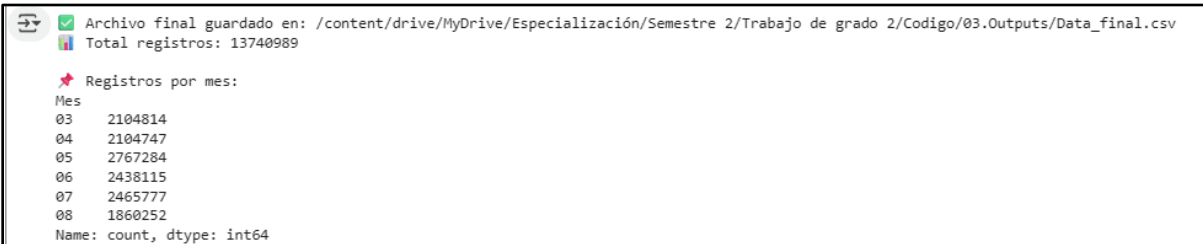
        resumen.append({"Mes": mes, "Registros": len(df)})
        print(f" {mes}_2025.csv leído con {len(df)} registros")
    else:
        print(f"⚠ No se encontró archivo para el mes: {mes}")

# 14. Unir todos los meses en un solo DataFrame
df_final = pd.concat(dfs, ignore_index=True)

# 15. Guardar como un único CSV
ruta_salida = os.path.join(output_folder, "Consolidado_2025.csv")
df_final.to_csv(ruta_salida, index=False, encoding='utf-8-sig')

print(f"\n Consolidado final guardado en: {ruta_salida}")
```

*Figura 11 Concatenación por mes*



```

✓ Archivo final guardado en: /content/drive/MyDrive/Especialización/Semestre 2/Trabajo de grado 2/Codigo/03.Outputs/Data_final.csv
Total registros: 13740989

★ Registros por mes:
Mes
03  2104814
04  2104747
05  2767284
06  2438115
07  2465777
08  1860252
Name: count, dtype: int64

```

*Figura 12 Salida concatenación*

En este punto del proceso, se trabajó con el archivo consolidado de todos los meses del año 2025 para realizar una revisión y validación final de los datos. Además, a este dataset se le incorporaron los datos históricos de la tasa bancario corriente y de la tasa de usura, los cuales complementan la información financiera disponible. Estos valores, que corresponden a promedios mensuales, se integraron directamente sobre las filas de cada mes, asegurando coherencia temporal.

El código presentado permite leer el archivo final, mostrar su estructura (número de registros y columnas) y realizar una previsualización de las primeras y últimas filas, además de listar los nombres de las columnas. Esta salida funciona como una verificación visual de que la información fue cargada y enriquecida correctamente, tal como se aprecia en la figura 13, donde se observa el dataset completo con las nuevas variables integradas.

El archivo tiene 13740989 registros y 10 columnas.

Primeras 10 filas:

	Nombre_Tipo_Entidad	Fecha_Corte	Mes	Producto de crédito	Tasa_efectiva_promedio_ponderada	Montos_desembolsados	Numero_de_creditos_desembolsados	Tipo_de_Tasa	INTERES_BC	TASA_USURA
0	BC-ESTABLECIMIENTO BANCARIO	2025-03-07	3	Libranza otros	22.36	79900000.0	4	FS	16.61	24.92
1	BC-ESTABLECIMIENTO BANCARIO	2025-03-07	3	Libranza otros	21.91	192750000.0	6	FS	16.61	24.92
2	BC-ESTABLECIMIENTO BANCARIO	2025-03-07	3	Libranza otros	20.98	58600000.0	1	FS	16.61	24.92

*Figura 13 Dataset completo*

## 9.4 Modelado

En este modelo se estableció un número determinado de épocas para controlar cuántas veces la red neuronal revisa y ajusta los datos de entrenamiento. Cada época representa una pasada completa por el conjunto de datos, en la que el modelo compara sus predicciones con los valores reales y corrige sus errores mediante un proceso de optimización. En este caso, se definieron 10 épocas cuando está activo el modo rápido (Ver figura 14) y 50 épocas cuando se entrena de forma completa, con el fin de equilibrar el tiempo de cómputo y la precisión del modelo. Un menor número de épocas permite realizar pruebas más ágiles, aunque con resultados menos exactos, mientras que un mayor número mejora el aprendizaje del modelo, pero requiere más tiempo de procesamiento.

El modelo fue construido utilizando una arquitectura LSTM (Long Short-Term Memory), diseñada especialmente para analizar series temporales y detectar patrones secuenciales. Está compuesto por una capa LSTM con 64 neuronas, seguida de una capa de salida densa con 2 neuronas, encargadas de predecir los valores de las dos variables objetivo: INTERES\_BC y TASA\_USURA.

```
# Asegurar que la fecha sea tipo datetime
df["Fecha_Corte"] = pd.to_datetime(df["Fecha_Corte"], errors="coerce")

# Filtrar filas válidas (donde haya tasas)
df_validos = df.dropna(subset=["INTERES_BC", "TASA_USURA"]).copy()

# Agrupar por semana (promedio semanal)
df_semana = df_validos.groupby("Fecha_Corte")[["INTERES_BC", "TASA_USURA"]].mean().reset_index()

# =====
# 2. Selección de modo
# =====
MODO_RAPIDO = True #

if MODO_RAPIDO:
    frac = 0.3 # 30% del dataset
    df_semana = df_semana.sample(frac=frac, random_state=42).sort_values("Fecha_Corte")
    print(f"Entrenando en modo rápido con {len(df_semana)} registros ({int(frac*100)}% del total)")
else:
    print(f"✅ Entrenando en modo completo con {len(df_semana)} registros")
```

Figura 14 Selección modo

```

# =====
# 4. Definir modelo LSTM
# =====
model = Sequential([
    Input(shape=(X.shape[1], X.shape[2])),
    LSTM(64, activation="relu"),
    Dense(2) # salida para INTERES_BC y TASA_USURA
])
model.compile(optimizer="adam", loss="mse")

# =====
# 5. Entrenamiento con tqdm
# =====
epochs = 10 if MODO_RAPIDO else 50
batch_size = 64
loss_history = []

for epoch in tqdm(range(epochs), desc="Entrenando modelo"):
    history = model.fit(X, y, epochs=1, batch_size=batch_size, verbose=0)
    loss_history.append(history.history["loss"][0])

```

*Figura 15 Modelo LSTM*

```

output_file = '/content/drive/MyDrive/Especialización/Semestre 2/Trabajo de grado 2/Codigc

# Leer CSV
df = pd.read_csv(input_file, dtype={"Mes": str})

# Diccionario con tasas (clave = Mes)
tasas = {
    "03": {"INTERES_BC": 16.61, "TASA_USURA": 24.92},
    "04": {"INTERES_BC": 17.08, "TASA_USURA": 25.62},
    "05": {"INTERES_BC": 17.31, "TASA_USURA": 25.97},
    "06": {"INTERES_BC": 17.03, "TASA_USURA": 25.55},
    "07": {"INTERES_BC": 16.52, "TASA_USURA": 24.78},
    "08": {"INTERES_BC": None, "TASA_USURA": None}, # Agosto se deja vacío
}

# Asignar columnas nuevas según Mes
df["INTERES_BC"] = df["Mes"].map(lambda m: tasas.get(m, {}).get("INTERES_BC"))
df["TASA_USURA"] = df["Mes"].map(lambda m: tasas.get(m, {}).get("TASA_USURA"))

```

*Figura 16 Anexo de tasas por mes*

En la primera gráfica (Ver figura 17) se observa la evolución y predicción de las tasas de interés: la línea azul representa la tasa del Bancario Corriente (INTERÉS\_BC) y la roja la tasa de usura real a lo largo de los meses analizados, desde marzo hasta julio de 2025. Los puntos marcados con "X" al final de cada serie corresponden a las predicciones generadas por el modelo para el mes de agosto, permitiendo comparar visualmente los valores estimados con las tendencias reales. Este gráfico busca mostrar cómo se comportan las tasas en el tiempo y evaluar si las predicciones del modelo se ajustan de manera coherente a la evolución histórica.

En la segunda gráfica (Ver figura 18) se presenta la evolución de la pérdida (loss) durante el entrenamiento del modelo, medida a través del error cuadrático medio (MSE). Aquí se puede ver una disminución constante del error a medida que avanzan las épocas, esta pérdida nos indica que el modelo está aprendiendo correctamente y mejorando su capacidad de predicción con cada iteración.

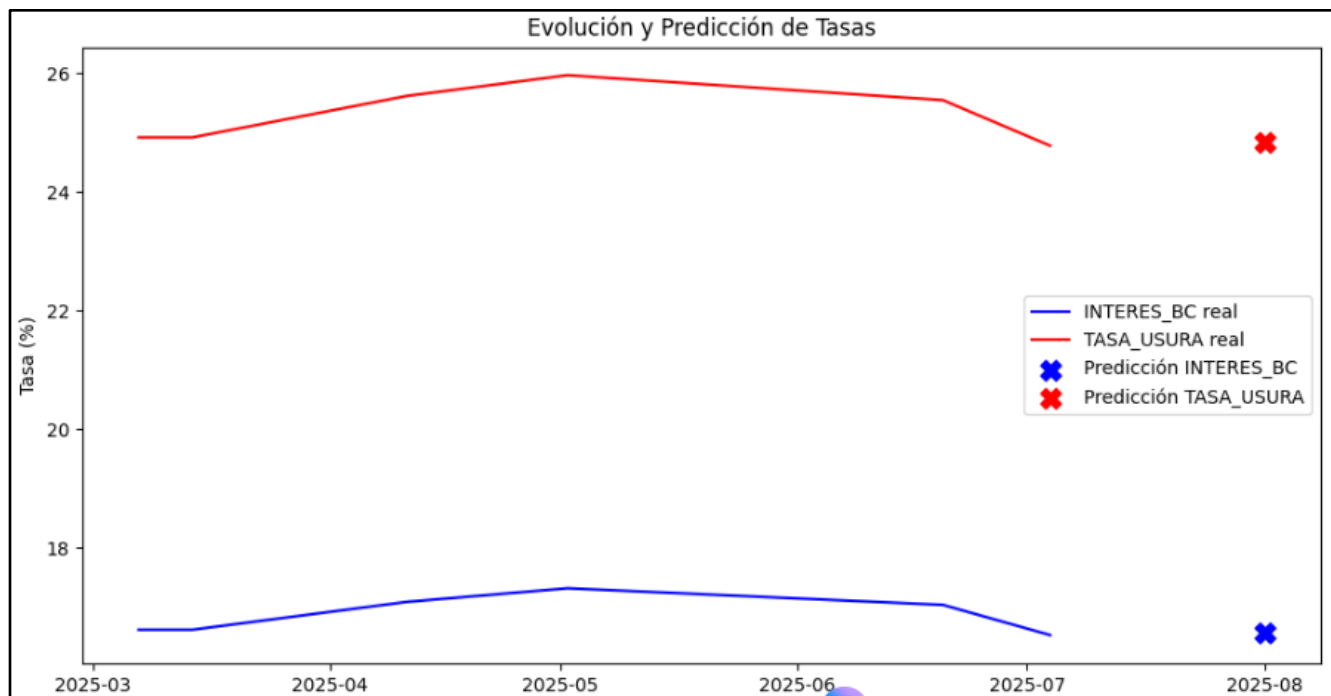


Figura 17 Evolución y predicción de tasas



*Figura 18 Evolución de pérdida en entrenamiento*

## 9.5 Evaluación y Despliegue

Cuando se evaluó el modelo con el modo rápido activado, se evidenció que al entrenar con una porción reducida de los datos (solo el 30%) y con pocas épocas, el modelo no logra captar correctamente los patrones históricos de las tasas. Esto se refleja en métricas menos favorables, donde el  $R^2$  negativo indica que el modelo no explica adecuadamente la variabilidad de los datos y sus predicciones son incluso peores que tomar un promedio simple. El RMSE (Root Mean Squared Error) y el MAE (Mean Absolute Error), que miden el error promedio entre los valores reales y los predichos, resultan relativamente altos, lo que confirma que las estimaciones no son tan precisas.

Por otro lado, cuando se desactiva el modo rápido y se entrena el modelo con todo el conjunto de datos y un número mayor de épocas, se observa que las predicciones se acercan mucho más a los valores reales, mostrando una relación más coherente con los comportamientos esperados. En este caso, el modelo tarda considerablemente más tiempo en generar las predicciones correctas, ya que debe procesar una mayor cantidad de información y pasar por muchas más iteraciones para ajustar sus pesos internos. Sin embargo, este esfuerzo adicional se traduce en una predicción que es más precisa y confiable, lo que demuestra que el tiempo de entrenamiento es un factor clave para mejorar el desempeño del modelo.

```
# =====  
# 6B. Métricas de rendimiento (Regresión)  
# =====  
# Predicciones sobre todos los datos  
y_pred = model.predict(X)  
y_pred_inv = scaler.inverse_transform(y_pred)  
y_true_inv = scaler.inverse_transform(y)  
  
# Calcular métricas  
rmse = np.sqrt(mean_squared_error(y_true_inv, y_pred_  
mae = mean_absolute_error(y_true_inv, y_pred_inv)  
r2 = r2_score(y_true_inv, y_pred_inv)  
  
print("\n📊 MÉTRICAS DE RENDIMIENTO (Regresión):")  
print(f"RMSE: {rmse:.4f}")  
print(f"MAE: {mae:.4f}")  
print(f"R²: {r2:.4f}")
```

*Figura 19 Métricas de rendimiento*

## 10. Conclusiones

- El aprendizaje de máquinas en la predicción financiera para Colombia representa una oportunidad clave para mejorar la toma de decisiones económicas y optimizar la gestión del riesgo. Estos modelos permiten anticipar fluctuaciones en tasas de interés, inflación y otros indicadores clave con mayor precisión, facilitando así estrategias más adaptativas para entidades financieras, reguladores y empresas.
- La implementación de modelos de predicción basados en analítica avanzada, modelos estadísticos y redes neuronales, como las LSTM, representan una herramienta que les da ventaja estratégica a las entidades financieras en Colombia. Esta implementación no solo mejora la toma de decisiones al prever variaciones en las tasas de interés bancario corriente y de usura, sino que también permite una mejor organización del portafolio de productos financieros, adaptabilidad frente a cambios de ley que se presenten y un cumplimiento más eficiente de las normativas impuestas por la Superintendencia Financiera.
- Los objetivos del proyecto se cumplieron de forma satisfactoria. Se desarrolló un modelo que permite predecir la Tasa de Interés Bancario Corriente y la Tasa de Usura en Colombia, combinando herramientas de análisis, aprendizaje automático y regresión logística. A lo largo del proceso, se aplicó la metodología CRISP-DM, lo que facilitó entender a fondo el contexto del negocio y organizar cada etapa de trabajo. Se analizaron los factores económicos y sociales que más influyen en la variación de las tasas de interés y se eligieron las variables más importantes para representarlos. Luego, se probaron diferentes enfoques de modelado hasta determinar el uso de la red LSTM que nos ofreció mejores resultados. Finalmente, el modelo fue probado y validado, mostrando que puede ser una herramienta útil para que las entidades financieras tomen decisiones más informadas y oportunas.

## 11. Referencias

1. Tasa de usura. (s/f). Gov.co. Recuperado el 29 de marzo de 2025, de <https://www.banrep.gov.co/es/glosario/tasa-usura>
2. ¿Qué es la Tasa de Interés? (s/f). CMF Educa - Comisión para el Mercado Financiero. Recuperado el 29 de marzo de 2025, de <https://www.cmfchile.cl/educa/621/w3-article-27164.html>
3. (S/f). Gov.co. Recuperado el 29 de marzo de 2025, de <https://www.superfinanciera.gov.co/loader.php?IServicio=Tools2&ITipo=descargas&IFuncion=descargar&idFile=5194#:~:text=1.,tasa%20de%20referencia%20del%20mercado.>
4. Radware Bot Manager Captcha. (s/f). Gov.co. Recuperado el 29 de marzo de 2025, de <https://www.banrep.gov.co/es/glosario/tasa-usura>
5. ¿Qué son las redes neuronales? (2024, noviembre 13). Ibm.com. <https://www.ibm.com/es-es/topics/neural-networks>
6. Teruel, S. (s/f). ¿Sabes en qué consisten los pronósticos financieros? Captio.net. Recuperado el 29 de marzo de 2025, de <https://www.captio.net/blog/en-que-consisten-los-pronosticos-financieros>
7. Microbank.com. <https://www.microbank.com/es/blog/p/-que-son-para-que-sirven-microcreditos.html>
8. (S/f). Gov.co. Recuperado el 29 de marzo de 2025, de <https://www.superfinanciera.gov.co/publicaciones/10115370/superfinanciera-certifica-el-interes-bancario-corriente/>
9. Schüler, Y. S. (2024). Filtering economic time series: On the cyclical properties of Hamilton's regression filter and the Hodrick-Prescott filter. *Review of Economic Dynamics*, 54(101237), 101237. <https://doi.org/10.1016/j.red.2024.101237>
10. Menéndez-García, L. A., García-Nieto, P. J., García-Gonzalo, E., & Sánchez Lasheras, F. (2024). Time series analysis for COMEX platinum spot price forecasting using SVM, MARS,

- MLP, VARMA and ARIMA models: A case study. *Resources Policy*, 95(105148), 105148.  
<https://doi.org/10.1016/j.resourpol.2024.105148>
11. Bhambu, A., Gao, R., & Suganthan, P. N. (2024). Recurrent ensemble random vector functional link neural network for financial time series forecasting. *Applied Soft Computing*, 161(111759), 111759. <https://doi.org/10.1016/j.asoc.2024.111759>
  12. Tian, S., & Hamori, S. (2015). Modeling interest rate volatility: A Realized GARCH approach. *Journal of Banking & Finance*, 61, 158–171. <https://doi.org/10.1016/j.jbankfin.2015.09.008>
  13. Li, J., Yang, X., Qian, T., & Xie, Q. (2023). The adaptive Fourier decomposition for financial time series. *Engineering Analysis with Boundary Elements*, 150, 139–153. <https://doi.org/10.1016/j.enganabound.2023.01.037>
  14. (S/f). Edu.co. Recuperado el 2 de abril de 2025, de <https://repository.urosario.edu.co/server/api/core/bitstreams/ed99ee81-8a78-4676-85a1-8de7e8f39668/content>
  15. Monterrey Mayoral, J., & Sánchez Segura, A. (2017). Una evaluación empírica de los métodos de predicción de la rentabilidad y su relación con las características corporativas. *Revista de contabilidad*, 20(1), 95–106. <https://doi.org/10.1016/j.rcsar.2016.08.001>
  16. de Mello, L., & Moccero, D. (2011). Monetary policy and macroeconomic stability in Latin America: The cases of Brazil, Chile, Colombia and Mexico. *Journal of International Money and Finance*, 30(1), 229–245. <https://doi.org/10.1016/j.jimonfin.2010.08.002>
  17. Quintero Otero, J. D. (2015). Impactos de la política monetaria y canales de transmisión en países de América Latina con esquema de inflación objetivo. *Ensayos sobre política económica*, 33(76), 61–75. <https://doi.org/10.1016/j.espe.2015.02.001>
  18. Murcia, A., & Rojas, D. (2014). Determinantes de la tasa de cambio en Colombia: un enfoque de microestructura de mercados. *Ensayos sobre política económica*, 32(74), 52–67. [https://doi.org/10.1016/s0120-4483\(14\)70027-2](https://doi.org/10.1016/s0120-4483(14)70027-2)
  19. Khakbaz, A., Mensi, W., Tirkolaei, E. B., Hammoudeh, S., & Simic, V. (2023). The combined effects of interest and inflation rates on inventory systems: A comparative analysis across

- countries. *International Journal of Production Economics*, 266(109035), 109035.  
<https://doi.org/10.1016/j.ijpe.2023.109035>
20. Gomez-Gonzalez, J. E., Sanin-Restrepo, S., Tamayo, C. E., & Valencia, O. M. (2023). Bank market power and firm finance: evidence from bank and loan-level data. *Economic Change and Restructuring*. <https://doi.org/10.1007/s10644-023-09570-0>
21. Agénor, P.-R., & Pereira da Silva, L. A. (2012). Macroeconomic stability, financial stability, and monetary policy rules: Macroeconomic stability, financial stability, and monetary policy rules. *International Finance*, 15(2), 205–224. <https://doi.org/10.1111/j.1468-2362.2012.01302.x>
22. (S/f). Editorialinnova.com. Recuperado el 3 de abril de 2025, de <https://editorialinnova.com/index.php/rig/article/view/103/314>
23. Restrepo, A. B. (s/f). Un método para optimización de portafolios de acciones colombianas con predicción de retorno basado en una técnica de machine learning. *Edu.co*. Recuperado el 3 de abril de 2025, de <https://repositorio.unal.edu.co/bitstream/handle/unal/85011/1036946147.2023.pdf?sequence=2&isAllowed=y>
24. Final, I. (s/f). POLÍTICA DE LA TASA DE USURA EN EL MERCADO FINANCIERO EN COLOMBIA: IMPLICACIONES, EFECTOS Y RECOMENDACIONES. *Org.co*. Recuperado el 3 de abril de 2025, de [https://www.repository.fedesarrollo.org.co/bitstream/handle/11445/4746/Repór\\_Marzo\\_2024\\_Cadena\\_et\\_al.pdf?sequence=12&isAllowed=y](https://www.repository.fedesarrollo.org.co/bitstream/handle/11445/4746/Repór_Marzo_2024_Cadena_et_al.pdf?sequence=12&isAllowed=y)
25. Pérez, H. R. A. (s/f). El Impacto de la Inteligencia Artificial y el Machine Learning en la Valoración de Activos Financieros. *Edu.ec*. Recuperado el 3 de abril de 2025, de <https://www.instituto-ohiggins.edu.ec/wp-content/uploads/2025/02/El-Impacto-de-la-Inteligencia-Artificial-y-el-Machine-Learning-en-la-Valoracion-de-Activos-Financieros.pdf>
26. Orlik, N. L. (2014). La política monetaria y el crecimiento económico: la tasa de interés de referencia del Banco de México. *Economía informa*, 387, 21–42. [https://doi.org/10.1016/s0185-0849\(14\)70435-9](https://doi.org/10.1016/s0185-0849(14)70435-9)
27. (S/f). *Bis.org*. Recuperado el 3 de abril de 2025, de <https://www.bis.org/publ/work717.pdf>

28. de la Hoz Granadillo, E. J., Herrera, T. J. F., & Gómez, J. M. (2014). Evaluación del comportamiento de los indicadores de productividad y rentabilidad financiera del sector petróleo y gas en Colombia mediante el análisis discriminante. *Contaduría y administración*, 59(4), 167–191. [https://doi.org/10.1016/s0186-1042\(14\)70159-7](https://doi.org/10.1016/s0186-1042(14)70159-7)
29. González, J. K. S. H., & Guillén, S. Y. M. (2017). ¿Por qué las tasas de interés son tan bajas? +. *Economía informa*, 405, 46–63. <https://doi.org/10.1016/j.ecin.2017.07.003>
30. (S/f). Researchgate.net. Recuperado el 3 de abril de 2025, de [https://www.researchgate.net/profile/Victor-Vazquez-4/publication/298641521\\_Modelado\\_y\\_prediccion\\_de\\_la\\_tasa\\_de\\_interes\\_interbancaria\\_de\\_equilibrio\\_en\\_Mexico\\_via\\_un\\_proceso\\_auto-recursivo\\_de\\_orden\\_uno/links/56ea108808ae3a5b48ccd134/Modelado-y-prediccion-de-la-tasa-de-interes-interbancaria-de-equilibrio-en-Mexico-via-un-proceso-auto-recursivo-de-orden-uno.pdf](https://www.researchgate.net/profile/Victor-Vazquez-4/publication/298641521_Modelado_y_prediccion_de_la_tasa_de_interes_interbancaria_de_equilibrio_en_Mexico_via_un_proceso_auto-recursivo_de_orden_uno/links/56ea108808ae3a5b48ccd134/Modelado-y-prediccion-de-la-tasa-de-interes-interbancaria-de-equilibrio-en-Mexico-via-un-proceso-auto-recursivo-de-orden-uno.pdf)
31. Gomez-Gonzalez, J. E., Banco de la República de Colombia, González-Molano, E., Huertas-Campos, C., Cristiano-Botia, D., Chavarro-Sanchez, X., Banco de la República de Colombia, Banco de la República de Colombia, Banco de la República de Colombia, & Banco de la República de Colombia. (2016). Evaluación de la transmisión de la tasa de interés de referencia a las tasas de interés del sistema financiero Colombiano. *Ecos de Economía*, 20(42), 19–45. <https://doi.org/10.17230/ecos.2016.42.2>
32. (S/f). Com.co. Recuperado el 3 de abril de 2025, de [https://scholar.google.com.co/scholar?q=Macroeconomic+Stability+and+Interest+Rate+Forecasting+in+Colombia&hl=es&as\\_sdt=0&as\\_vis=1&oi=scholart](https://scholar.google.com.co/scholar?q=Macroeconomic+Stability+and+Interest+Rate+Forecasting+in+Colombia&hl=es&as_sdt=0&as_vis=1&oi=scholart)
33. Final, I. (s/f). POLÍTICA DE LA TASA DE USURA EN EL MERCADO FINANCIERO EN COLOMBIA: IMPLICACIONES, EFECTOS Y RECOMENDACIONES. Org.co. Recuperado el 3 de abril de 2025, de [https://www.repository.fedesarrollo.org.co/bitstream/handle/11445/4746/Repor\\_Marzo\\_2024\\_Cadena\\_et\\_al.pdf?sequence=12&isAllowed=y](https://www.repository.fedesarrollo.org.co/bitstream/handle/11445/4746/Repor_Marzo_2024_Cadena_et_al.pdf?sequence=12&isAllowed=y)

34. Análisis de las tasas de interés de. (s/f). Core.ac.uk. Recuperado el 3 de abril de 2025, de <https://core.ac.uk/download/pdf/327695328.pdf>

35. (S/f). Filesusr.com. Recuperado el 27 de abril de 2025, de [https://4b78d60e-b139-4c77-84c5-2f009677d9c4.filesusr.com/ugd/bd4eb1\\_c99dca3985f94319909b772e2c7ac162.pdf](https://4b78d60e-b139-4c77-84c5-2f009677d9c4.filesusr.com/ugd/bd4eb1_c99dca3985f94319909b772e2c7ac162.pdf)