



**FACULTAD DE POSTGRADO
TRABAJO FINAL DE GRADUACIÓN**

**ANÁLISIS COMPARATIVO DE MODELOS DE MACHINE
LEARNING Y ECONOMETRÍA LINEAL PARA LA
PREDICCIÓN DEL CRÉDITO BANCARIO HONDUREÑO
BASADOS EN LA TASA DE POLÍTICA MONETARIA (2010–
2025)**

SUSTENTADO POR:

**ALLAN ENRIQUE PINEDA GARCIA
JUAN MANUEL FLORES ZELAYA**

PREVIA INVESTIDURA AL TÍTULO DE

**MÁSTER EN
ANALÍTICA DE NEGOCIOS**

TEGUCIGALPA, FRANCISCO MORAZAN, HONDURAS, C.A.

MAYO, 2026

**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA
UNITEC**

FACULTAD DE POSTGRADO

AUTORIDADES UNIVERSITARIAS

RECTORA

ROSALPINA RODRÍGUEZ

VICERRECTOR ACADÉMICO NACIONAL

JAVIER ABRAHAM SALGADO LEZAMA

SECRETARIO GENERAL

ROGER MARTÍNEZ MIRALDA

DECANA FACULTAD DE POSTGRADO

ANA DEL CARMEN RETTALLY VARGAS

**ANÁLISIS COMPARATIVO DE MODELOS DE
MACHINE LEARNING Y ECONOMETRÍA LINEAL
PARA LA PREDICCIÓN DEL CRÉDITO BANCARIO
HONDUREÑO BASADOS EN LA TASA DE POLÍTICA
MONETARIA (2010–2025)**

**TRABAJO PRESENTADO EN CUMPLIMIENTO DE LOS
REQUISITOS EXIGIDOS PARA OPTAR AL TÍTULO DE
MÁSTER EN
ANALÍTICA DE NEGOCIOS**

ASESOR

JESUS RICARDO RODRIGUEZ RIVERA

MIEMBROS DE LA TERNA:

**ANTHONY STEVE BARAHONA
ESPINOZA**

**DAVID ANTONIO MEJIA DIAZ
KEVIN EDUARDO FÚNEZ FÚNEZ**

DERECHOS DE AUTOR

© Copyright 2026
Allan Enrique Pineda Garcia
Juan Manuel Flores Zelaya

Todos los derechos son reservados.



FACULTAD DE POSTGRADO

**ANÁLISIS COMPARATIVO DE MODELOS DE MACHINE
LEARNING Y ECONOMETRÍA LINEAL PARA LA
PREDICCIÓN DEL CRÉDITO BANCARIO HONDUREÑO
BASADOS EN LA TASA DE POLÍTICA MONETARIA (2010–
2025)**

Allan Enrique Pineda Garcia

Juan Manuel Flores Zelaya

Resumen

Esta investigación desarrolla y evalúa modelos de machine learning para la predicción del crédito bancario hondureño en función de la tasa de política monetaria y otros indicadores macroeconómicos, utilizando datos mensuales del período 2010–2025 provenientes del Banco Central de Honduras. Se comparan modelos tradicionales con algoritmos como Random Forest, XGBoost y Lasso mediante métricas de error fuera de la muestra. Los resultados muestran una superioridad consistente de los modelos de machine learning en precisión predictiva y captura de relaciones no lineales, proponiéndose como herramienta de apoyo para la política monetaria del Banco Central de Honduras.

Palabras claves: (Crédito bancario, Machine Learning, Política monetaria, Predicción macroeconómica, Tasa de política monetaria)



GRADUATE SCHOOL

**ANÁLISIS COMPARATIVO DE MODELOS DE MACHINE
LEARNING Y ECONOMETRÍA LINEAL PARA LA
PREDICCIÓN DEL CRÉDITO BANCARIO HONDUREÑO
BASADOS EN LA TASA DE POLÍTICA MONETARIA (2010–
2025)**

Allan Enrique Pineda Garcia

Juan Manuel Flores Zelaya

Abstract

This research develops and evaluates machine learning models for forecasting Honduran bank credit as a function of the monetary policy rate and other macroeconomic indicators, using monthly data from 2010 to 2025 obtained from the Central Bank of Honduras. Traditional econometric models are compared with algorithms such as Random Forest, XGBoost, and Lasso using out-of-sample error metrics. The results show a consistent superiority of machine learning models in predictive accuracy and in capturing nonlinear relationships, supporting their use as a decision-support tool for monetary policy at the Central Bank of Honduras.

Palabras claves: (Bank credit, Machine Learning, Monetary policy, Macroeconomic forecasting, Monetary policy rate)

DEDICATORIA

A Ana Santos y al pequeño Emiliano: mi motor, mi refugio. Todo lo que soy se los debo a su compañía. Camus decía que crear es vivir dos veces; nuestra familia es nuestra más grande creación, y los amo con la inmensidad de mil soles. A mi madre Elsa Zelaya, por ser siempre una fuente de inspiración y admiración.

Juan Manuel Flores Zelaya

Dedicado a Lucysbella, mi dulce gatita, que me ha acompañado cada día y noche durante la elaboración de esta tesis; a mi amigo Juan Flores, quien ha estado presente en los momentos difíciles y felices; y, de manera muy especial, a la memoria de mi hermano Guillermo Ezequiel Pineda, quien ya no está físicamente conmigo, pero cuyas palabras permanecen en mi corazón. Él siempre creyó en mí, me recordó que estaba preparado para grandes cosas y que poseía la inteligencia para alcanzarlas. Esta tesis también es para él.

Allan Enrique Pineda Garcia

AGRADECIMIENTO

Gracias a mi familia por siempre apoyarme en todas mis aventuras, gracias a mis compañeros de equipos con los que hicimos amistad y gracias a Allan por no rendirnos a pesar de las dificultades mira ahora donde estamos.

Juan Manuel Flores Zelaya

Gracias al creador del universo, por darme la valentía e iluminación para seguir adelante, a mis amigos y familiares, por tener confianza en mí.

Allan Enrique Pineda Garcia

ÍNDICE DE CONTENIDO

DEDICATORIA.....	ix
AGRADECIMIENTO	x
ÍNDICE DE CONTENIDO	xi
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN	20
1.1 INTRODUCCIÓN.....	20
1.2 ANTECEDENTES DEL PROBLEMA	21
1.2.1 DINAMICA DE LA ESTABILIDAD FINANCIERA EN HONDURAS	21
1.2.2 RELEVANCIA TEORICA Y CONTRIBUCIÓN AL CONOCIMIENTO	21
1.3 DEFINICIÓN DEL PROBLEMA	22
1.4 PREGUNTAS DE INVESTIGACIÓN	23
1.5 OBJETIVOS DE LA INVESTIGACIÓN	24
1.6 JUSTIFICACIÓN.....	25
1.6.1 RELEVANCIA TEORICA Y CONTRIBUCIÓN AL CONOCIMIENTO	25
1.6.2 RELEVANCIA METODOLOGICA	25
1.6.3 RELEVANCIA PRÁCTICA Y SOCIAL	26
1.6.4 ANÁLISIS DE CAUSA-RAÍZ DEL PROBLEMA.....	26
CAPÍTULO II. MARCO TEÓRICO	28
2.1 ANÁLISIS DE MACROENTORNO.....	28
2.1.1 SUDAMÉRICA (PERÚ Y CHILE).....	28
2.1.2 INDIA	30
2.1.3 KENIA	31
2.1.4 HONDURAS	33
2.1.5 SINTESIS COMPARATIVA	34
2.2 ANÁLISIS DE MICROENTORNO	36
2.2.1 COSTA RICA.....	36
2.2.2 GUATEMALA	37
2.2.3 EL SALVADOR.....	38
2.2.4 HONDURAS	38
2.3 CONCEPTUALIZACIÓN.....	42

2.3.1	CREDITO BANCARIO EN EL SECTOR PRIVADO	42
2.3.2	TASA DE POLÍTICA MONETARIA (TPM)	42
2.3.3	TRANSMISIÓN MONETARIA	43
2.3.4	NO LINEALIDAD MACROFINANCIERA.....	44
2.3.5	REZAGOS	44
2.3.6	MODELOS ECONOMÉTRICOS TRADICIONALES.....	45
2.3.7	MACHINE LEARNIG (ML).....	45
2.3.8	MODELOS DE ENSAMBLE (RANDOM FOREST Y XGBOOST).....	45
2.3.9	SERIES DE TIEMPO MACROECONOMICAS	46
2.3.10	INTERPRETABILIDAD EN ML (EXPLAINABLE AI - XAI)	46
2.4	TEORÍAS DE SUSTENTO	47
2.4.1	TEORÍA DE LA INFORMACIÓN ASIMÉTRICA	47
2.4.2	TEORÍA DE ACELERACIÓN FINCANCIERO Y CICLO DEL CREDITO	47
2.4.3	CANAL DE PRÉSTAMO BANCARIO Y TRANSMICIÓN BANCARIA	48
2.4.4	NO LINEALIDAD EN LA TRASMICIÓN MONETARIA Y EN LAS RELACIONES MACROECONOMICAS	49
2.4.5	APRENDIZAJE AUTOMÁTICO CON ÉNFASIS A INFERENCIA EMPIRICAS (APRENDIZAJE ESTADÍSTICO)	50
2.5	ANTECEDENTES DE METODOLOGÍAS UTILIZADAS	50
2.6	ANTECEDENTES METODOLÓGICOS.....	52
2.7	ENFOQUES, MÉTODOS Y DISEÑO	53
2.8	ANÁLISIS CRÍTICO DE METODOLOGÍAS	54
2.9	HERRAMIENTAS Y SOFTWARE	55
2.10	MARCO LEGAL.....	59
2.10.1	MARCO INTERNACIONAL	59
2.10.2	MARCO NACIONAL (HONDURAS)	60
CAPÍTULO III. METODOLÓGIA DE INVESTIGACIÓN.....		62
3.1	CONGRUENCIA METODOLÓGICA	62
3.1.1	MATRIZ METODOLÓGICA	63
3.1.2	ESQUEMA DE VARIABLES DE ESTUDIO	65
3.1.3	MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES.....	67
3.1.4	HIPÓTESIS	71

3.2	ENFOQUE Y MÉTODOS	73
3.3	DISEÑO DE LA INVESTIGACIÓN.....	74
3.3.1	POBLACIÓN.....	74
3.3.2	MUESTRA	75
3.3.3	TÉCNICAS DE MUESTREO	75
3.3.4	CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN.....	76
3.4	TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS	78
3.4.1	TÉCNICAS.....	79
3.4.2	INSTRUMENTOS.....	81
3.4.3	PROCEDIMIENTOS APLICADOS	82
3.5	FUENTES DE INFORMACIÓN	84
3.5.1	FUENTES SECUNDARIAS (ORIGEN OFICIAL).....	85
3.5.2	FUENTES SECUNDARIAS BIBLIOGRÁFICAS Y TÉCNICAS.....	87
3.6	PLAN DE ANÁLISIS.....	88
CAPÍTULO IV. RESULTADOS Y ANÁLISIS		97
4.1	ANÁLISIS EXPLORATORIO DE DATOS (EDA).....	97
4.1.1	DESCRIPCIÓN GENERAL DEL CONJUNTO DE DATOS.....	98
4.1.2	LIMPIEZA Y PREPARACIÓN DE LOS DATOS	100
4.1.3	VISUALIZACIÓN DE DATOS	102
4.1.4	CONCLUSIONES DEL EDA	107
4.2	INFORME DEL PROCESO DE RECOLECCIÓN DE DATOS.....	109
4.2.1	DESCRIPCIÓN DEL PROCESO DE RECOLECCIÓN.....	109
4.2.2	PARTICIPANTES O FUENTES DE INFORMACIÓN	110
4.2.3	INSTRUMENTOS UTILIZADOS	111
4.2.4	DIFICULTADES ENCONTRADAS	113
4.2.5	CONSIDERACIONES ÉTICAS	114
4.3	RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS.....	116
4.3.1	RESULTADOS CUANTITATIVOS.....	116
4.3.1.1	PRESENTACIÓN DE LOS DATOS.....	116
4.3.1.2	DESCRIPCIÓN DE LOS HALLAZGOS.....	119
4.3.1.3	RELACIÓN CON LOS OBJETIVOS	121
4.3.1.4	ANÁLISIS ESTADÍSTICO.....	124
4.3.2	ANÁLISIS CUALITATIVO	129
4.3.2.1	CATEGORÍAS O TEMAS EMERGENTES.....	130
4.3.2.2	CITAS O EJEMPLOS	131
4.3.2.3	INTERPRETACIÓN	133
4.3.2.4	TRIANGULACIÓN	134

4.4	ANÁLISIS INFERENCIAL Y MODELOS APLICADOS	136
4.4.1	ANÁLISIS INFERENCIAL	136
4.4.2	MODELOS APLICADOS	138
4.4.3	DISCUSIÓN DE HALLAZGOS	142
4.4.4	LIMITACIONES.....	144
4.5	SÍNTESIS DE HALLAZGOS	146
4.5.1	PRINCIPALES HALLAZGOS.....	146
4.5.2	IMPLICACIONES	147
4.5.3	TRANSICIÓN AL CAPÍTULO V.....	149
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....		149
5.1	CONCLUSIONES.....	149
5.2	RECOMENDACIONES	152
CAPÍTULO VI. APLICABILIDAD		154
6.1	NOMBRE DE LA PROPUESTA.....	154
6.2	JUSTIFICACIÓN DE LA PROPUESTA	155
6.3	ALCANCE DE LA PROPUESTA	159
6.3.1	OBJETIVO GENERAL DEL PROYECTO	160
6.3.2	OBJETIVOS ESPECIFICOS DEL PROYECTO	160
6.4	DESCRIPCIÓN Y DESARROLLO	161
6.4.1	DESCRIPCIÓN	161
6.4.2	DESARROLLO	162
6.5	MEDIDAS DE CONTROL	180
6.6	CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO.....	183
6.7	PRESUPUESTO E IMPACTO DE LA PROPUESTA.....	188
6.7.1	PRESUPUESTO DE RECURSOS HUMANOS	188
6.7.2	PRESUPUESTO DE INFRAESTRUCTURA Y SOFTWARE BAJO ARQUITECTURA LIGERA CON STREAMLIT	189
6.7.3	PRESUPUESTO GENERAL	190
6.7.4	ESCENARIO PERT DEL PRESUPUESTO	190
6.7.5	CÁLCULO DEL RETORNO DE LA INVERSIÓN	191
6.7.6	IMPACTO CUANTITATIVO Y CUALITATIVO.....	193

6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA.....	193
REFERENCIAS BIBLIOGRÁFICAS.....	200
ANEXOS.....	207

ÍNDICE DE FIGURAS

Ilustración 1 Descomposición de causas del problema de pronóstico del crédito bancario (2010–2025)	27
Ilustración 2 Diagrama del esquema de variables	66
Ilustración 3 Diagrama de flujo del plan de análisis de datos (fases 1–5)	92
Ilustración 4 Estadísticos descriptivos de las variables macrofinancieras (2010-01 a 2025-08)	99
Ilustración 5 Medidas de forma y pruebas de normalidad de las variables (2010-01 a 2025-08)	99
Ilustración 6 Matrices de correlación	103
Ilustración 7 Figura FORENCE QQ BOX pre y post COVID	104
Ilustración 8 KDE vs normal crédito nivel vs log	105
Ilustración 9 CCF logaritmo del TPM (KDE = 0.24)	106
Ilustración 10 diagramas acf y pacf	107
Ilustración 11 Evolución del crédito al sector privado y TPM en Honduras	118
Ilustración 12 Resumen del crédito al sector privado (2010-01 a 2025-08)	119
Ilustración 13 Observaciones atípicas en el crecimiento del crédito identificadas por el método IQR	121
Ilustración 14 Correlaciones entre el crecimiento mensual del crédito y determinantes macrofinancieros por subperíodo (coeficientes PEARSON y SPEARMAN, IC 95% por BOOTSTRAP y ajuste FDR)	122
Ilustración 15 Resumen descriptivo por subperiodos económicos (PRE-COVID, COVID, POST-COVID): niveles, dispersión y dinámica del crédito y variables macrofinancieras	123
Ilustración 16 Diferencias entre subperiodos en variables macroeconómicas y del crédito (WELCH T-TEST, MANN-WHITNEY, KOLMOGOROV-SMIRNOV Y LEVENS; tamaños de EFECTO; P ajustados por FDR)	123
Ilustración 17 Resultados de estacionariedad (ADF y KPSS)	125
Ilustración 18 Medidas de forma y pruebas de normalidad	125
Ilustración 19 CCF TPM - log(crédito) (k=0-24)	127

Ilustración 20 Causalidad de GRANGER (TPM -> crédito)	128
Ilustración 21 Resultados de la prueba de cointegración de ENGLE–GRANGER entre logaritmo del crédito y TPM	137
Ilustración 22 Desempeño de los modelos econométricos aplicados	139
Ilustración 23 Desempeño de los modelos de ML	139
Ilustración 24 Métricas comparativas entre ambos tipos de modelos y gráfico comparativo en la prueba de ambos modelos con walk-forward	141
Ilustración 25 Resultado de la prueba de DIEBOLD-MARIANO robusta	142
Ilustración 26 Causas fundamentales para la justificación de la propuesta	159
Ilustración 27 Diagrama de arquitectura de despliegue	162
Ilustración 28 BPMN algoritmo operativo mensual	164
Ilustración 29 Portada del reporte	168
Ilustración 30 Resumen ejecutivo	168
Ilustración 31 Pronostico del siguiente periodo	169
Ilustración 32 Métricas de desempeño del sistema	170
Ilustración 33 Variables relevantes del ciclo	171
Ilustración 34 Alertas del sistema	172
Ilustración 35 Contexto macrofinanciero	173
Ilustración 36 Nota metodológica y cierre	174
Ilustración 37 Entregable 6 mockup del módulo 1: panel principal	175
Ilustración 38 Entregable 6 mockup del módulo 2: tablero de métricas de desempeño	176
Ilustración 39 Entregable 6 mockup del módulo 3: variables relevantes seleccionadas por el modelo lasso	177
Ilustración 40 Entregable 6 mockup del módulo 4: panel de alertas del sistema con estado activo o inactivo	178
Ilustración 41 Entregable 6 mockup del módulo 5: contexto macrofinanciero	179
Ilustración 42 Diagrama de Gantt de actividades	185
Ilustración 43 Alineación vertical de la investigación con la propuesta	194

ÍNDICE DE TABLAS

Tabla 1	Análisis de macroentorno usando PESTEL	35
Tabla 2	Comparativo regional: Cinco Fuerzas de Porter	39
Tabla 3	Herramientas para análisis de datos	55
Tabla 4	Herramientas para reproducibilidad, control de versiones y gestión del código....	57
Tabla 5	Herramientas para redacción académica, referencias, diagramas y presentación	58
Tabla 6	Marco legal internacional relevante.....	60
Tabla 7	Marco legal y regulatorio nacional.....	61
Tabla 8	Matriz metodológica del estudio.....	64
Tabla 9	Esquema de variables del estudio	66
Tabla 10	Matriz de operacionalización de las variables.....	69
Tabla 11	Red PERT del plan de análisis (pipeline cuantitativo)	93
Tabla 12	Descripción de las variables del estudio.....	116
Tabla 13	Estadísticas descriptivas del panel de datos (2010 - 2025)	118
Tabla 14	Análisis comparativo por períodos económicos	118
Tabla 15	Fundamentos de la propuesta	155
Tabla 16	Resumen de entregables de la propuesta	163
Tabla 17	Resumen de fases del algoritmo operativo mensual	165
Tabla 18	Procedimiento de actualización mensual	166
Tabla 19	plan de contingencia ante ausencia de variables.....	167
Tabla 20	Resumen de indicadores de control.....	180
Tabla 21	Ficha metodológica del KPI-01. Precisión del pronóstico del crédito bancario..	180
Tabla 22	Ficha metodológica del KPI-02. Estabilidad del sistema de pronóstico	181
Tabla 23	Ficha metodológica del KPI-03. Oportunidad de actualización del sistema	181
Tabla 24	Ficha metodológica del KPI-04. Uso analítico efectivo del sistema.....	182
Tabla 25	Ficha metodológica del KPI-05. Calidad y trazabilidad del dato y del proceso .	182
Tabla 26	Cronograma de implementación y seguimiento de la propuesta.....	184
Tabla 27	Cronograma PERT varianza por actividad y ruta critica	186
Tabla 28	Probabilidades de cumplimiento del cronograma por horizonte temporal	187

Tabla 29 Presupuesto de talento humano.....	189
Tabla 30 Presupuesto estimado de infraestructura y software con Streamlit	190
Tabla 31 Presupuesto general de la propuesta.....	190
Tabla 32 Escenario PERT del presupuesto reformulado.....	191
Tabla 33 Análisis del retorno de la inversión reformulado.....	192
Tabla 34 Matriz de concordancia.....	195

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1 INTRODUCCIÓN

El crédito bancario es uno de los principales motores económicos, ya sea al facilitar el consumo, la compra de bienes en hogares y la inversión en las empresas. Debido a su rol central en la estabilidad financiera, la capacidad de la autoridad monetaria para anticipar el crecimiento futuro del crédito es esencial para la gestión macroeconómica.

En el contexto de Honduras, la modelación predictiva del crédito cobra una crucial relevancia. La economía hondureña muestra un fortalecimiento y resultados macroeconómicos positivo en 2024, con un crecimiento económico del 3.6% y una inflación con una tasa baja y estable del 3.88%. El crédito otorgado al sector privado alcanzó el 78.2% del Producto Interno Bruto (PIB) en 2024, plantándose como el más alto en Centroamérica (Banco Central de Honduras, 2024b). Este crecimiento constante vuelve importante la predicción de este dado su impacto en la economía hondureña.

Esta investigación tiene como objetivo mejorar la predicción del crédito bancario, mediante la aplicación de algoritmos de Machine Learning (ML) y centrada en la tasa de política monetaria (TPM).

El Banco Central de Honduras implementa políticas monetarias y crediticias. En 2024 el TPM acumulado era de 275 puntos básicos (bp) hasta llegar a un 5.75% a final de año (Banco Central de Honduras, 2024b). Esta busca ser restrictiva y guiar la economía, lo que impacta directamente a esta dado el aumento de la tasa de interés activa sobre operaciones nuevas en moneda nacional al 16.54% a finales del 2024 frente a un 11.68% en 2023 (Banco Central de Honduras, 2024a). Por estas condiciones más restrictivas el ritmo del crédito bancario fue más lento en 2024, un hecho que demuestra la necesidad de predecir el impacto que tienen las TPM en el crecimiento del crédito y la economía del país.

Esta investigación se estructura de la siguiente manera:

Capítulo I: presenta el planteamiento del problema, exponiendo el problema, las preguntas de investigaciones, objetivos, justificación y el análisis causa raíz.

Capítulo II: se desarrolla el marco teórico, el análisis de macroentorno y microentorno, conceptualización de las variables claves y las teorías de sustento de esta investigación y los modelos propuestos.

Capítulo III: Se detalla la metodología del estudio, describe el diseño, las variables, operacionalización, las técnicas de análisis y los instrumentos utilizados para validar los modelos predictivos propuestos en esta investigación.

1.2 ANTECEDENTES DEL PROBLEMA

Esta sección proporciona el fundamento histórico, la magnitud del fenómeno de estudio y el estado de los modelos financieros.

1.2.1 DINAMICA DE LA ESTABILIDAD FINANCIERA EN HONDURAS

El crédito bancario del sector bancario representa un pilar importante y de apoyo al crecimiento del país; este representa el canal de transmisión de las políticas monetarias (PM) y actúa como motor de los financiamientos de los sectores productivos. En Honduras, la relevancia particular es marcada, alcanzando un volumen equivalente al 78.2% del PIB, nivel superior al de economías comparables (Banco Central de Honduras, 2024a).

Esta elevada proporción señala el impacto directo que tiene sobre la economía, la inversión y la estabilidad financiera del país. En 2024, el Banco Central de Honduras llevó a cabo cambios en la política monetaria de 275 puntos (pb), lo que lo colocó en un 5.7% al fin del año. Este ajuste se trasladó a la tasa de interés del sistema financiero del país; la tasa activa en moneda nacional aumentó en 16.54%(Banco Central de Honduras, 2024a). A pesar de este endurecimiento en la (PM), la cartera mostró una desaceleración moderada, lo que evidencia:

- Presencia de rezagos temporales en la circulación del dinero.
- Posibles efectos no lineales entre las políticas monetarias y el crédito.
- La necesidad de herramientas para predecir la complejidad macroeconómica.

1.2.2 RELEVANCIA TEORICA Y CONTRIBUCIÓN AL CONOCIMIENTO

Las literaturas que aborda el pronóstico del crédito se han desarrollado bajo dos marcos metodológicos, que representan limitaciones importantes en economías en desarrollo como la hondureña:

1. Limitantes de la econometría tradicional (Pronóstico Agregado):

Los modelos tradicionales de econometría como ARIMA, VAR, ARFIMA se han implementado haciendo uso de la proyección de series financieras y monetarias gracias a su estructura formal y relativa facilidad de interpretación. Sin embargo, estos enfoques parten de la linealidad, estabilidad y efectos simétricos, que son difíciles de mantener en entornos como el nuestro dónde choques externos, volatilidad inflacionaria o fluctuaciones en los tipos de cambio aplican.

Estudios internacionales muestran que los modelos lineales suelen mostrar problemas para anticipar inflexiones, capturar no linealidad y responder de manera adecuada a cambios macroeconómicos. Estos estudios demuestran que los errores tienden a aumentar en entornos de alta incertidumbre (Araujo & Gaglianone, 2023; Baya et al., 2025) y que su eficacia depende de supuestos que difícilmente se cumplen en economías emergentes como la hondureña.

2. Avances en Machine Learning (ML) y el enfoque en datos complejos:

De forma paralela los modelos de ML han mostrado su aplicabilidad en modelos financieros y macroeconómicos, modelos como Random Forest, XGBoost y Redes LSTM y GRU muestran ser superiores en la captura de patrones no lineales y en la anticipación de patrones complejos en series financieras (Coulombe et al., 2020; Smalter Hall, 2018).

Aunque las investigaciones anteriores se centran en lo micro (riesgo individual, scoring crediticio), otras literaturas más recientes muestran la aplicabilidad a lo macro (predicción de inflación, pronóstico de tipo de cambio y crecimiento de crédito) (C. Giraldo et al., 2024; Kristina Bluwstein et al., 2021). No obstante, los avances internacionales, no existe evidencia en el pronóstico del crédito en Honduras, lo que muestra un vacío metodológico en el país.

1.3 DEFINICIÓN DEL PROBLEMA

El crecimiento económico hondureño está intrínsecamente ligado a la estabilidad y expansión del crédito bancario. Este depende del comportamiento de las políticas monetarias, la inflación y el tipo de cambio. Sin embargo, la capacidad de predicción del impacto de esta está

limitada por su complejidad, no linealidad, volatilidad y complejidad del país. Cosa que los modelos tradicionales no son capaces de hacer por asumir la linealidad entre las variables.

Investigaciones internacionales demuestran que los modelos ML son capaces de capturar estas relaciones complejas con mayor precisión (Coulombe et al., 2020; C. Giraldo et al., 2024; Sadhwani et al., 2021; Smalter Hall, 2018). Sin embargo, estas no se ven trasladadas al contexto hondureño.

Por lo tanto, el problema de este estudio es:

La insuficiencia predictiva de los modelos tradicionales de econometría lineal en describir el impacto de la tasa de política monetaria en crédito bancario del sistema financiero hondureño, debido a su falta de capacidad de captura de relaciones no lineales, volatilidad entre indicadores macroeconómicas claves (TPM, Crecimiento PIB, tasa de cambio).

1.4 PREGUNTAS DE INVESTIGACIÓN

Pregunta general de investigación:

En (P) el pronóstico del crédito bancario hondureño (2010-2025), ¿la (I) aplicación y validación de modelos de Machine Learning (ML) basados en la Tasa de Política Monetaria, en (C) comparación con los modelos econométricos lineales tradicionales, (O) mejora la precisión predictiva y la robustez en la captura de la dinámica no-lineal del sistema financiero?

Preguntas específicas:

1. ¿En (P) la serie histórica del crédito bancario hondureño, ¿cómo la (I) identificación y selección de las variables macroeconómicas y monetarias (TPM, Inflación, etc.) que influyen en el crédito, en (C) comparación con los modelos univariantes, ¿(O) aportan mayor poder explicativo al modelo predictivo de ML?
2. En (P) el periodo 2010-2025, ¿cómo la (I) implementación y entrenamiento de modelos de Machine Learning (Random Forest o XGBoost), en (C) comparación con los métodos estadísticos de series de tiempo lineales (ARIMA), (O) mejora la capacidad predictiva, demostrada por una reducción significativa en el error (RMSE) del pronóstico del crédito bancario?

3. Dado (P) el modelo de Machine Learning con el mejor rendimiento, ¿cómo la (I) aplicación de técnicas de interpretabilidad como SHAP o LIME, en (C) comparación con un modelo black-box, (O) contribuye a la comprensión de los diversos factores económicos que impulsan la predicción del crédito bancario, fortaleciendo la objetividad de las recomendaciones de política monetaria?

1.5 OBJETIVOS DE LA INVESTIGACIÓN

Desarrollar (S) un modelo de Machine Learning para pronosticar el crédito bancario agregado hondureño usando el TPM y variables macroeconómicas oficiales del BCH, (M) alcanzando un R^2 ajustado > 0.85 y/o un RMS $< 5\%$ en el conjunto de pruebas fuera de la muestra, (A) mediante el entrenamiento, ajuste y validación temporal con datos mensuales disponibles, (R) para disponer de una herramienta predictiva más robusta para el análisis macrofinanciero y de riesgo sistemático, (T) utilizando el periodo 2010-2025 como horizonte de estudio.

Objetivos Específicos:

- Establecer (S) las variables macroeconómicas y financieras (como la TPM, inflación y PIB) que tienen una correlación significativa con el crecimiento del crédito bancario, (M) mediante análisis exploratorios y de correlación (A), utilizando datos oficiales del BCH (T) durante la primera fase de la investigación.
- Medir (S) el rendimiento de al menos dos modelos de Machine Learning (Regresión Lineal múltiple, Regresión Lasso, Random Forest, XGBoost o LSTM) frente al modelo benchmarking lineal tradicional, (M) con la meta de alcanzar una mejora de al menos 15% en la reducción del error predictivo (RMSE) (A), (R) para establecer la capacidad predictiva superior de las técnicas no-lineales, (T) durante la fase de modelado experimental del proyecto.
- Interpretar (S) el impacto económico y la contribución de las variables predictivas en el mejor modelo de ML, (M) mediante la aplicación de técnicas de interpretabilidad (SHAP/LIME) (A), (R) para traducir los resultados técnicos en recomendaciones de política monetaria y financiera concretas, (T) durante la última etapa de validación.

1.6 JUSTIFICACIÓN

1.6.1 RELEVANCIA TEORICA Y CONTRIBUCIÓN AL CONOCIMIENTO

Este estudio posee un valor teórico significativo al centrarse en la validación de modelos de Machine Learning en series de tiempo macroeconómicas en el contexto de una economía en desarrollo (Honduras). La literatura internacional sobre ML en finanzas se basa a menudo en contextos con gran volumen de datos y alta estabilidad. En contraste, esta investigación evalúa la superioridad predictiva de ML en un entorno con menor volumen de información y mayor volatilidad política y económica, aportando evidencia empírica crucial sobre la aplicabilidad y eficacia de estas metodologías en nuevos contextos.

En nuestro caso, Honduras, como una economía en desarrollo, presenta características distintas como irregularidades económicas, políticas crediticias restrictivas y el volumen de datos usados para esa investigación no supera los doce mil registros, con lo cual esta investigación adquiere una relevancia teórica al evaluar la capacidad de estos modelos en entornos con menor volumen de información y políticas financieras más volátiles. Esto vienen a contribuir la aplicación de estos modelos en nuevos contextos, fortaleciendo el conocimiento de la analítica de negocios y el riesgo financiero.

Para terminar con un enriquecimiento del conocimiento local y regional mediante la generación de evidencia empírica sobre relación estadística que existen entre las variables (financieras, sociodemográficas y crediticias), el nivel de riesgos y la probabilidad de compra en el mercado inmobiliario hondureño, un tema poco abordado en las literaturas regionales y que termina contribuyendo al constructo teórico de los modelos predictivos en la región y Latinoamérica.

1.6.2 RELEVANCIA METODOLOGICA

Desde la perspectiva metodológica, el estudio se centra en contrastar la hipótesis de que la variabilidad en el crédito bancario responde a relaciones no-lineales. Al emplear modelos de Machine Learning, el estudio valida la necesidad de expandir los marcos de predicción más allá de los modelos lineales tradicionales, lo que contribuye al constructo teórico de la Econometría Aplicada y la Analítica de Negocios. Adicionalmente, la integración de técnicas de interpretabilidad asegura que el modelo de ML no sea una "caja negra", sino una herramienta

transparente que permite a los economistas y reguladores entender las razones de las predicciones, fortaleciendo la validez y aceptación de la técnica en la toma de decisiones.

Por ello este estudio busca validar si la variabilidad en el riesgo crediticio y la devolución en el sector inmobiliario responden a relaciones no lineales lo que implícitamente contribuye a la validación del uso de ML y DL en contexto de datos limitados.

Adicionalmente, la integración de métodos de interpretabilidad como SHAP y LIME permiten comprender el detrás de las decisiones de compra o riesgo crediticio en los modelos que dan paso a una comprensión de las razones de las decisiones de los modelos, fortaleciendo la transparencia y valides de los modelos dentro de la disciplina de la analítica de datos.

1.6.3 RELEVANCIA PRÁCTICA Y SOCIAL

En el contexto social, este estudio busca un conocimiento más justo y realista del mercado inmobiliario hondureño, al identificar las causas de la alta tasa de pérdidas de oportunidades. Este puede dar pie a una guía para que las empresas diseñen sus productos inmobiliarios de forma que se adapten a las necesidades reales y capacidades de la sociedad hondureña, buscando el fortalecimiento entre el análisis de datos y el desarrollo económico local.

La aplicación de este estudio se traduce en beneficios directos para la estabilidad financiera del país. Al dotar al BCH y a los bancos de una herramienta predictiva más precisa, se mejora la capacidad de:

- **Formulación de Política Monetaria:** El BCH puede calibrar su TPM y sus reservas con mayor anticipación a los ciclos crediticios.
- **Gestión de Riesgo Sistémico:** Las instituciones financieras obtienen mejores proyecciones de su exposición agregada, optimizando la asignación de capital y mitigando riesgos de liquidez.

En el contexto social, un sistema financiero más estable y predecible se traduce en un mercado de crédito más eficiente, fomentando la inversión y el desarrollo económico local.

1.6.4 ANÁLISIS DE CAUSA-RAÍZ DEL PROBLEMA

Con el fin de comprender las causas estructurales de la imprecisión en los pronósticos del crédito bancario en Honduras, se hace uso del diagrama de Ishikawa (causa – efecto).

Como resultado del análisis, se identifica como causa raíz la incompatibilidad estructural entre los supuestos lineales de los modelos econométricos tradicionales y la dinámica macrofinanciera no lineal del sistema hondureño, lo cual limita la precisión de los pronósticos del crédito bancario.



Ilustración 1 Descomposición de causas del problema de pronóstico del crédito bancario (2010–2025)

Fuente: Elaboración propia.

CAPÍTULO II. MARCO TEÓRICO

En este capítulo se establecen los fundamentos teóricos, conceptuales y metodológicos que dan sustento a esta investigación orientada a la predicción del crédito bancario hondureño mediante modelos de machine learning basada en la Tasa de Política Monetaria (TPM) y otros indicadores claves del Banco Central de Honduras (BCH) enfocado en un análisis de macroeconomías y financieros comparando economías similares a las Hondureñas para identificar factores, rigidez, fricciones y características propias de economías emergentes. Así mismo se desarrollan conceptos claves y teorías que sustentan la existencia de relaciones no lineales y rezagos en la respuesta del crédito frente al TPM. También se aborda la adopción de una metodología de investigación, herramientas de software y analíticas utilizadas con el fin de dar un soporte académico a esta investigación y finalmente se analiza el marco legal para establecer los agentes legislativos que influyen directa o indirectamente sobre esta investigación.

2.1 ANÁLISIS DE MACROENTORNO

El análisis de macroentorno busca comparar desde la perspectiva global, pero en economías similares a la hondureña para identificar las similitudes financieras, políticas o estructurales que condiciones la eficacia de las políticas monetarias. Para lo que se tomó como referencia tres regiones:

- Sudamérica (Perú y Chile)
- Asia (India)
- África (Kenia)

Con esta se busca evidencia fricciones y asimetrías que tienen significancia para esta investigación. Para esto se contrastará los factores **políticos, económicos, sociales, tecnológicos y legales (PESTEL)** que tienen impacto en la efectividad de las políticas monetarias y en el crédito bancario.

2.1.1 SUDAMÉRICA (PERÚ Y CHILE)

Chile y Perú representan al caso de referencia más cercano de una perspectiva al ideal teórico de lo que es una economía emergente con marcos monetarios formalizados. Ambos países

operan bajo regímenes de metas explícitas de inflación con bancos centrales con una alta credibilidad e independencia institucional.

P – Factor político

En bancos centrales Chile y Perú, se observan diferencia marcadas en la forma de manejo de la política monetaria. En Sudamérica, particularmente en Chile y Perú, los bancos centrales operan bajo un esquema de metas explícitas de inflación, lo que permite a estas instituciones tener una mayor autonomía y credibilidad en la gestión. Esto fortalece los canales de la tasa de interés, permitiendo que los ajustes monetarios se reflejen de forma más ordenada lo que se ve reflejado en el crédito financiero (Deb, 2023).

E - Factor económico

Desde un punto de vista económico, Sudamérica (Peru y Chile) presentan colchones macroeconómicos relativamente robustos, lo que permite que los ciclos de endurecimiento monetarios afecten con desaceleración gradual del crédito sin generar interrupciones abruptas en el crédito (Deb, 2023). Esto favorece a tener relaciones más previsibles entre el crédito y el TPM.

S – Factor social

Los países sudamericanos analizados desde la perspectiva social presentan niveles bancarios más elevados y una confianza mayor en las entidades financieras, lo que expande el número de personas que pueden aplicar a un crédito y favorece una transmisión monetaria más amplia (Demirgüç-Kunt et al., 2022). Esta heterogeneidad implica que el crédito bancario agregado responde de forma diferenciada a los cambios en la TPM según el segmento de la economía, introduciendo no linealidades en la relación agregada.

T – Factor tecnológico

Del factor tecnológico, los sistemas financieros de Chile y Peru muestran una adopción en aumento de la banca digital y uso de herramientas analíticas para la gestión del riesgo, aunque los canales tradicionales siguen prevaleciendo (Demirgüç-Kunt et al., 2022). La transformación digital está en curso, pero no ha alterado de forma estructural los canales de intermediación financiera ni la sensibilidad del crédito a la política monetaria.

L – Factor legal

En términos legales y regulatorios, Chile y Perú operan bajo un marco prudencial alineados con estándares de Basilea III y sistemas de supervisión fundamentados en el riesgo, lo que favorece la estabilidad financiera y la seguridad en el crédito (Deb, 2023). La previsibilidad del marco regulatorio es, en sí misma, un factor que contribuye a la estabilidad del canal de crédito.

Implicación para la investigación: Sudamérica representa el caso de mayor similitud con los supuestos del canal de tasas clásico. La estabilidad institucional, macroeconómica y regulatoria hace que la transmisión monetaria sea más lineal y previsible. Sin embargo, incluso en este contexto, los rezagos temporales y las fricciones de información asimétrica (Stiglitz & Weiss, 1981) generan no linealidades que justifican el uso de modelos capaces de capturar patrones complejos.

2.1.2 INDIA

India representa un caso de transmisión monetaria compleja en una economía de gran escala. Su banco central el Reserve Bank of India (RBI) opera bajo un marco de metas de inflación flexible que combina objetivos de estabilidad de precios con un mandato explícito de estabilidad financiera, en un contexto de crecimiento económico acelerado y expansión rápida del crédito minorista.

P – Factor político

En India, el marco político combina metas de inflación financiera flexible con un mandato explícito de estabilidad financiera, en un contexto de una economía de gran escala y una elevada dinámica crediticia (Reserve Bank of India, 2024). Esto introduce episodios de rápida expansión crediticia y ajustes regulatorios que pueden agregar asimetría y cambios de régimen en la relación entre el TMP y el crédito.

E - Factor económico

En la India, el alto crecimiento económico y la rápida expansión del crédito minorista generan riesgos en el apalancamiento de los hogares, lo que introduce mayor sensibilidad del crédito a los cambios macroeconómicos y regulatorios (Reserve Bank of India, 2024).

S – Factor social

En la India aunque existe una aceleración bancaria, la diferencia entre casco urbano y rural presenta diferencias significativas, lo que introduce heterogeneidad a la respuesta del crédito (Reserve Bank of India, 2024).

T – Factor tecnológico

Por su parte India, cuenta con una infraestructura avanzada de pago digital y expansión a plataformas de crédito digital que transforman los procesos de intermediación financiera, lo que altera los canales de crédito tradicionales (Reserve Bank of India, 2024).

L – Factor legal

En India las reformas en la insolvencia y en la regulación bancaria han tenido como objetivo mejorar la capacidad de adaptación bancaria y optimizar el manejo de riesgo (Reserve Bank of India, 2024). Sin embargo, estos ajustes regulatorios generan quiebres discretos en las series de crédito que son difíciles de modelar con enfoques lineales estáticos.

Implicación para la investigación: India ilustra cómo la escala económica, la expansión acelerada del crédito y la transformación tecnológica pueden desestabilizar la relación TPM crédito a través de cambios de régimen y efectos no lineales.

2.1.3 KENIA

Representa el caso más disruptivo en cuanto a la transformación del canal de transmisión monetaria. La masificación del dinero móvil a través de plataformas como M-Pesa ha reconfigurado de forma estructural la intermediación financiera del país, generando un ecosistema donde el crédito bancario formal compite directamente con productos financieros digitales de acceso masivo

P – Factor político

En Kenia, la política monetaria se implementa en un entorno abierto a la innovación financiera, aquí el banco central utiliza una tasa de referencia para controlar la inflación, pero enfrenta la coexistencia de canales alternativos financieros asociados al dinero mediante aplicaciones móviles (Suri & Jack, 2016).

E – Factor económico

En Kenia, el crecimiento impulsado por el sector de servicios y la competencia al crédito bancario con productos asociados a las remesas y el dinero móvil reduce el rol de los sistemas bancarios como canal de transmisión monetaria (Suri & Jack, 2016). La política monetaria opera en un sistema donde los mecanismos de transmisión son múltiples y no todos pasan por el canal bancario tradicional.

S – Factor social

En Kenia, la expansión del dinero móvil a una gran proporción de la población ha permitido que estos tenga acceso a servicios financieros básicos lo que a su vez ha modificado la estructura tradicional de intermediación financiera (Suri & Jack, 2016).

T — Factor Tecnológico

Kenia es reconocida como líder global en ecosistemas de dinero móvil y plataformas fintech reguladas como emisores de dinero electrónico (Breloff & Tarazi, 2010). M-Pesa y sus derivados han transformado por completo la forma en que personas y empresas acceden a liquidez y crédito, generando un sistema donde la transmisión monetaria depende no solo de la tasa de referencia, sino también de la dinámica de adopción tecnológica y de los shocks en las plataformas digitales. Este factor introduce relaciones altamente no lineales que los modelos estadísticos convencionales no pueden capturar.

L – Factor legal

En Kenia, se han impulsado regulaciones para los emisores no bancarios de dinero electrónico, así como esquemas de salvaguarda de los activos de los clientes, lo que favorece la expansión hacia servicios financieros alternativos (Breloff & Tarazi, 2010).

Implicación para la investigación: Kenia demuestra que la innovación tecnológica puede alterar fundamentalmente la estructura del canal de transmisión monetaria, haciendo que la relación entre la tasa de referencia y el crédito bancario agregado sea dependiente de factores tecnológicos exógenos. Este caso justifica el uso de modelos flexibles y no paramétricos capaces de capturar relaciones cambiantes e influencias externas al sistema de tasas.

2.1.4 HONDURAS

El análisis revela un conjunto de condiciones estructurales que condicionan la efectividad de la TPM como instrumento de política monetaria y generan relaciones no lineales, heterogéneas y con cambios de régimen en la dinámica del crédito bancario agregado. Comprender estas condiciones es esencial para justificar metodológicamente el uso de modelos de aprendizaje automático en lugar de enfoques lineales estáticos.

P – Factor político

En Honduras, el Banco Central de Honduras utiliza el TPM explícita, su efectividad se ven limitada por la dolarización parcial y la alta dependencia a las remesas, lo que afecta de manera directa la capacidad del instrumento monetarios para influir de manera directa y proporcional sobre el crédito (Deb, 2023; International Monetary Fund, 2011). Ambas condiciones reducen el margen de maniobra del instrumento monetario, dado que una parte significativa de la liquidez del sistema proviene de flujos externos que no responden a la TPM local. En consecuencia, los ajustes de la tasa de política monetaria no se transmiten de forma proporcional ni homogénea hacia el crédito bancario agregado.

E - Factor económico

En el caso de Honduras, el crédito en el sector privado alcanza niveles elevados en relación con su nivel de ingresos, lo que incrementa la sensibilidad del sistema a choques externos y cambios en la TPM (Deb, 2023; International Monetary Fund, 2011). Esto combinado con la dependencia a las remesas, genera una transmisión monetaria más heterogénea y aumenta la probabilidad de no linealidad.

S – Factor social

En Honduras la adopción de la banca es media y una parte de los hogares y la micro, pequeña y mediana empresa sigue dependiendo de cooperativas o crédito informal, lo que limita el crédito bancario y la respuesta homogénea a los cambios en la TPM (Demirgüç-Kunt et al., 2022). Los cambios en la TPM afectan directamente al segmento formal, pero su influencia sobre los segmentos informales es indirecta y más lenta, lo que introduce heterogeneidad en la respuesta del crédito agregado.

T – Factor tecnológico

Honduras por su parte presenta procesos lentos en temas de digitalización financiera, con una mayoría de bancos móviles y transferencia electrónica, pero con una limitada adopción de fintech de crédito a gran escala, lo que restringe la innovación hacia canales de acceso al crédito (Demirgüç-Kunt et al., 2022). La baja penetración tecnológica reduce la posibilidad de que innovaciones disruptivas hayan alterado estructuralmente la relación histórica entre la TPM y el crédito en el período analizado.

L – Factor legal

La Comisión Nacional de Bancos y Seguros ha fortalecido el marco prudencial en Honduras al estandarizar la evaluación y clasificación de la cartera crediticia, a través de regulaciones como la Circular C-003-2022. Esto puede provocar cambios sutiles en lo que respecta a la oferta crediticia, así como rupturas en las series temporales (Comisión Nacional de Bancos y Seguros, 2022).

Implicación para la investigación: El PESTEL de Honduras identifica cuatro condiciones estructurales que, en conjunto, generan una transmisión monetaria compleja, heterogénea y con alta probabilidad de no linealidad: (i) dolarización financiera parcial que limita el alcance de la TPM; (ii) dependencia de remesas que introduce liquidez exógena al sistema; (iii) bancarización intermedia que segmenta la respuesta del crédito; y (iv) ajustes regulatorios de la CNBS que pueden generar quiebres estructurales en las series. Estas condiciones respaldan metodológicamente la decisión de adoptar modelos de aprendizaje automático con validación temporal estricta, capaces de aprender relaciones complejas, rezagos variables y cambios de régimen, en lugar de modelos lineales que asumen estacionariedad y proporcionalidad.

2.1.5 SINTESIS COMPARATIVA

El análisis PESTEL por país permite identificar que, aunque los cuatro casos comparten rasgos de economías emergentes, la efectividad de la TPM y su transmisión hacia el crédito bancario dependen de configuraciones estructurales específicas que varían significativamente entre cada nación. La Tabla 1 sintetiza los hallazgos más relevantes de cada factor para facilitar la comparación.

TABLA 1 Análisis de macroentorno usando PESTEL

Factor PESTEL	Sur América (Perú y Chile)	India	Kenia	Honduras
Político (P)	Los bancos centrales hacen uso de metas explícitas de inflación.	Opera bajo un marco de metas de inflación flexible con un mandato explícito de estabilidad financiera.	Utiliza una tasa de referencia para controlar la inflación en un entorno abierto a la innovación.	TPM explícita, pero en un contexto de dolarización financiera parcial y elevada dependencia de remesas.
Económico (E)	Economías con colchones macroeconómicos relativamente robustos.	Crecimiento elevado y rápida expansión del crédito.	Crecimiento impulsado por servicios.	El crédito al sector privado alcanza niveles elevados respecto al PIB para su nivel de ingreso.
Social (S)	Niveles de bancarización relativamente altos y mayor confianza en las instituciones.	Falta de inclusión financiera entre zonas urbanas y rurales.	La mayoría de los hogares disponga de servicios financieros básicos a través de dinero móvil.	Bancarización intermedia; muchos hogares y MIPYME siguen dependiendo de cooperativas o crédito informal.
Tecnológico (T)	Sistemas bancarios con adopción creciente de banca digital y uso de analítica en la gestión de riesgo.	Infraestructura avanzada de pagos digitales (UPI) y expansión de plataformas de crédito digital.	Liderazgo en ecosistemas de dinero móvil y plataformas fintech reguladas como emisores de dinero electrónico.	Proceso incipiente de digitalización financiera: mayor uso de banca móvil y transferencias electrónicas.
Legal (L)	Marcos prudenciales alineados con Basilea III y supervisión basada en riesgos.	Regulación bancaria orientadas a mejorar la resiliencia del sistema y la gestión de riesgos.	Regulación específica para emisores no bancarios de dinero electrónico y esquemas de protección de los fondos de los clientes.	Marco prudencial reforzado; la CNBS estandariza la evaluación y clasificación de la cartera crediticia mediante normas.

Fuente: Elaboración propia.

De este análisis comparado se desprende que la transmisión de la política monetaria al crédito bancario no es un proceso uniforme ni lineal. Sudamérica representa el caso de mayor cercanía al canal clásico de tasas, con marcos institucionales estables y transmisión más previsible. India introduce complejidad por escala, dinámica crediticia y transformación tecnológica. Kenia evidencia cómo la innovación puede rediseñar completamente los canales de transmisión. Honduras, por su parte, reúne condiciones dolarización parcial, remesas, bancarización intermedia,

ajustes regulatorios que producen una transmisión monetaria heterogénea, con rezagos variables y alta probabilidad de relaciones no lineales. Esta evidencia comparada justifica, de forma sólida y metodológicamente rigurosa, la decisión de emplear modelos de aprendizaje automático parsimoniosos con validación temporal estricta para el pronóstico del crédito bancario hondureño.

2.2 ANÁLISIS DE MICROENTORNO

Para el microentorno financiero se toma como referencia el modelo de las cinco fuerzas de PORTER aplicado al sistema financiero centroamericano haciendo énfasis a Costa Rica, Guatemala y El Salvador como un caso de análisis de regímenes similares al nuestro, para dar paso a una comparación del caso de Honduras.

2.2.1 COSTA RICA

Rivalidad entre competidores: La rivalidad se clasifica como moderada–alta, debido a la coexistencia de bancos públicos y privados y la competencia por productos, tasas y segmentos, aunque dentro de un mercado relativamente concentrado. La presencia de banca pública tiende a presionar condiciones de mercado y obliga a la banca privada a diferenciar oferta, especialmente en crédito de consumo y MIPYMES (Banco Central de Costa Rica, 2024).

Poder de negociación de los prestatarios. Este es moderado. La mayor bancarización e infraestructura financiera amplían la capacidad de comparación de ofertas (tasas/plazos), aunque persisten asimetrías informativas para hogares y microempresas. Esta combinación sugiere que cambios en condiciones monetarias pueden trasladarse con mayor visibilidad al cliente final, pero no necesariamente de forma proporcional (Demirgüç-Kunt et al., 2022).

Poder de negociación de los depositantes. Es moderado: la TPM influye como referencia en tasas pasivas, pero la concentración limita cuánto pueden presionar los depositantes por mejores rendimientos. En la práctica, la competencia por depósitos existe, pero no es perfecta (Banco Central de Costa Rica, 2024).

Amenaza de nuevos entrantes. Es moderada. Los requisitos regulatorios y de capital elevan barreras de entrada a la banca tradicional; sin embargo, existe expansión fintech, principalmente en pagos y servicios, con penetración todavía limitada en crédito bancario masivo.

Amenaza de sustitutos. Se clasifica como baja–moderada. Cooperativas y crédito informal existen, pero el crédito bancario formal mantiene predominio en financiamiento de consumo e inversión formal.

Implicación para la tesis. Costa Rica representa un mercado donde el canal de tasas puede ser relativamente más transparente hacia el prestatario, pero la concentración preserva fricciones. Esto es consistente con la hipótesis de que incluso en entornos más profundos, la transmisión puede mantener rezagos y no linealidades.

2.2.2 GUATEMALA

Rivalidad entre competidores. La rivalidad se clasifica como **moderada–baja**, porque el mercado presenta alta concentración en pocos bancos grandes con poder de mercado y márgenes relativamente altos. Esta estructura tiende a reducir la competencia agresiva por precio, especialmente en segmentos de menor riesgo.

Poder de negociación de los prestatarios. Es **bajo**, debido a la alta informalidad, menor inclusión financiera y limitaciones en información crediticia para amplios segmentos, lo cual reduce la capacidad de comparar y negociar condiciones (Demirgüç-Kunt et al., 2022). En este contexto, los prestatarios suelen enfrentar condiciones más rígidas y acceso segmentado.

Poder de negociación de los depositantes. Se considera **bajo**, porque el fondeo del sistema se ve influido por flujos externos (remesas), reduciendo la presión por competir agresivamente por depósitos domésticos. Cuando el fondeo es relativamente holgado, la tasa pasiva tiende a ajustarse menos por competencia y más por estrategia bancaria.

Amenaza de nuevos entrantes. Es **moderada**. Existen cooperativas y fintech con crecimiento, pero la banca tradicional permanece protegida por regulación prudencial y barreras de capital.

Amenaza de sustitutos. Se clasifica como **alta**, por la relevancia del crédito informal, cooperativas y entidades no reguladas en segmentos de bajos ingresos, que compiten directamente con la banca formal en acceso y rapidez.

Implicación para la tesis. Guatemala es un ejemplo de entorno donde la transmisión monetaria hacia el crédito puede ser **más lenta y heterogénea**, porque los bancos dominantes ajustan condiciones (cupos, estándares) más que tasas, reforzando no linealidad.

2.2.3 EL SALVADOR

Rivalidad entre competidores. La rivalidad se considera **baja–moderada**. La concentración y el riesgo soberano condicionan márgenes y apetito crediticio, reduciendo la competencia basada en precio.

Poder de negociación de los prestatarios. Es **bajo**: alternativas limitadas y condiciones de crédito influenciadas por riesgo país y estructura concentrada. El prestatario enfrenta rigideces y ajustes por riesgo que dominan la dinámica de tasas.

Poder de negociación de los depositantes. Se clasifica como **bajo**. Al operar en un entorno dolarizado, las condiciones pasivas se alinean más con referencia externa y percepción de riesgo que con competencia doméstica pura.

Amenaza de nuevos entrantes. Se considera **moderada–alta**. La infraestructura digital y pagos facilita entrada de proveedores no bancarios y plataformas, con mayor dinamismo relativo que en sistemas donde la moneda local y la regulación bancaria concentran más la intermediación.

Amenaza de sustitutos. Es **alta**, por el uso intensivo de efectivo, plataformas de pagos y crédito no bancario como sustitutos parciales del crédito formal (International Monetary Fund, 2013).

Implicación para la tesis. El Salvador muestra un microentorno donde shocks externos y condiciones en dólares pueden amplificar cambios de régimen, haciendo más probable que modelos lineales fallen en capturar la dinámica de crédito ante cambios monetarios y financieros.

2.2.4 HONDURAS

Rivalidad entre competidores. En Honduras la rivalidad es **limitada** debido a la alta concentración de activos y cartera en pocos bancos, reduciendo competencia en precio y condiciones. Esto habilita ajustes discrecionales de la oferta de crédito por estándares y segmentación más que por variaciones proporcionales en tasas (Banco Central de Honduras, 2024a; Comisión Nacional de Bancos y Seguros, 2024)

Poder de negociación de los prestatarios. Es **bajo**: baja inclusión financiera e informalidad restringen alternativas formales para hogares y MIPYMES. En este contexto, el prestatario tiende a absorber condiciones fijadas por banca dominante, con menor capacidad de negociación.

Poder de negociación de los depositantes. Se clasifica como **bajo–moderado**. El flujo sostenido de remesas incrementa liquidez sistémica, lo que reduce incentivos para elevar tasas pasivas agresivamente. Esto implica que el costo de fondeo puede ajustarse de forma imperfecta a cambios monetarios, afectando el canal de tasas.

Amenaza de nuevos entrantes. Es **baja** en banca tradicional por barreras regulatorias y capital, mientras que fintech aún se concentra en pagos y billeteras, con impacto limitado en crédito bancario masivo.

Amenaza de sustitutos. Es **moderada–alta**. Cooperativas, microfinancieras y crédito informal atienden segmentos excluidos, pero no sustituyen el rol sistémico de la banca en estabilidad financiera agregada.

Implicación para la tesis. Dadas la concentración y las fricciones, la respuesta del crédito ante cambios en TPM no debe asumirse inmediata ni proporcional. Los bancos pueden ajustar cupos, estándares, plazos y composición de cartera, generando **rezagos, asimetrías y no linealidad**; por ello es coherente evaluar modelos no lineales (ML) frente a modelos de referencia lineales.

TABLA 2 Comparativo regional: Cinco Fuerzas de Porter

Fuerza	Costa Rica	Guatemala	El Salvador	Honduras
Rivalidad entre competidores	Moderada alta: bancos públicos y privados; competencia en tasas/productos en mercado concentrado.	Moderada baja: alta concentración en pocos bancos con márgenes elevados.	Baja–moderada: concentración alta; márgenes condicionados por riesgo país/condiciones externas.	Limitada: concentración de activos/cartera reduce competencia en precio y condiciones.
Poder de los prestatarios	Moderado: mayor bancarización permite comparar, aunque persiste asimetría para hogares/MIPYME S.	Bajo: informalidad e información crediticia limitada; alternativas restringidas.	Bajo: alternativas limitadas; condiciones marcadas por riesgo soberano y estructura de mercado.	Bajo: hogares y MIPYME S con alternativas formales limitadas; baja inclusión e informalidad.
Poder de depositantes (proveedores)	Moderado: TPM guía tasas pasivas; concentración reduce presión por mayores rendimientos.	Bajo: remesas como fondeo reduce competencia	Bajo: tasas alineadas a condiciones en dólares y riesgo país más que a competencia doméstica.	Bajo moderado: remesas elevan liquidez y reducen competencia agresiva por depósitos.

Fuerza	Costa Rica	Guatemala	El Salvador	Honduras
Amenaza de nuevos entrantes	Moderada: requisitos regulatorios/capital; fintech crece, pero aún pequeña en crédito bancario.	por depósitos domésticos. Moderada: fintech y cooperativas crecen; núcleo bancario sigue regulado.	Moderada–alta: dolarización y pagos digitales facilitan entrada de plataformas/proveedores no bancarios.	Baja (banca tradicional): altos requisitos; fintech incipiente en crédito (más en pagos).
Amenaza de sustitutos	Baja–moderada: cooperativas/crédito informal existen, pero banca domina financiamiento formal.	Alta: crédito informal y entidades no reguladas compiten fuertemente en segmentos bajos.	Alta: efectivo, pagos digitales y entidades no bancarias sustituyen parcialmente al crédito formal.	Moderada–alta: cooperativas/microfinancieras/crédito informal cubren excluidos sin sustituir rol sistémico bancario.

Fuente: Elaboración propia.

El análisis del microentorno financiero a partir de las cinco fuerzas de Porter nos permite ver similitudes estructurales y diferencias relevantes en la forma que el sistema financiero responde a los cambios de la tasa de política monetaria. Aparte de sus particularidades nacionales, los cuatro países comparten un grado elevado de concentración bancaria que condicionan la competencia y la oferta de crédito.

En Costa Rica, aunque existe una mayor competencia entre bancos públicos y privados, el mercado se mantiene concentrado, lo que limita la presión que esta competencia puede ejercer sobre la oferta crediticia. Sin embargo, el acceso a la información bancaria y el mayor número de banca habientes le otorga a esto una mayor capacidad de negociación superior al resto de los países lo que favorece una transmisión más directa aunque no necesariamente proporcional de los cambios de tasa de referencia hacia el crédito (Banco Central de Costa Rica, 2024; Demirgüç-Kunt et al., 2022).

Honduras comparte con Guatemala y El Salvador una estructura bancaria altamente concentrada y bajo poder de negociación para los hogares y MIPYMES. Sin embargo, aunque en presentan sustitutos financieros los bancos mantienen un rol dominante en la estabilidad financiera agregada, lo que les otorga un poder para poder modificar estándares de aprobación, plazos y

segmentos de cartera de forma discreta lo que genera respuestas no lineales y asimetrías dentro del crédito antes cambios de la tasa de política monetaria.

En este entorno, la respuesta del crédito bancario hondureño a cambios en la TPM no puede suponerse proporcional ni inmediatamente. Los bancos pueden ajustar márgenes, modificar estándares de aprobación, cambiar la composición de cartera o privilegiar determinados segmentos, generando una respuesta no lineal y con rezagos. Las características del entorno externo e interno convergen en tres implicaciones metodológicas clave para la tesis:

No linealidad y cambios de régimen

La experiencia internacional muestra que, en presencia de profundización financiera, remesas significativas y sistemas bancarios concentrados, la relación entre tasas de interés y crédito no es lineal ni estable. Modelos de ML aplicados a series macroeconómicas han probado ser superiores a modelos lineales para capturar este tipo de patrones, especialmente cuando se combinan múltiples variables financieras (Bluwstein et al., 2021; Coulombe et al., 2020).

Uso intensivo de información macrofinanciera oficial

Honduras dispone de series oficiales de TPM, tasas activas y pasivas, tipo de cambio, inflación y crédito al sector privado publicadas por el BCH y la CNBS, mientras que el FMI y el Banco Mundial proporcionan estadísticas comparables a nivel internacional (Banco Central de Honduras, 2024a; Comisión Nacional de Bancos y Seguros, 2024; Deb, 2023; International Monetary Fund, 2011). Esta disponibilidad de datos estructurados es ideal para entrenar modelos de ML.

Relevancia para la estabilidad financiera

Trabajos recientes centrados en crecimiento del crédito y riesgo sistémico utilizan ML para construir indicadores tempranos de tensiones financieras, explotando información sobre la curva de rendimientos y la expansión del crédito (Bluwstein et al., 2023). Del mismo modo, estudios sobre monitoreo de creación de crédito a alta frecuencia en economías emergentes proponen herramientas basadas en ML como insumo operativo para bancos centrales (C. Giraldo et al., 2024).

En este contexto, desarrollar y validar un modelo de ML que prediga el crédito bancario hondureño a partir de **la TPM y otros indicadores macrofinancieros** no solo responde al problema de insuficiencia de los modelos lineales, sino que se alinea con las mejores prácticas internacionales en materia de pronóstico macrofinancieros y gestión de riesgos.

2.3 CONCEPTUALIZACIÓN

En esta sección abordamos los conceptos centrales abordados, lo que proporciona un marco común dentro del contexto hondureño e internacional, para comprender las políticas monetarias, el crédito bancario y la aplicabilidad en modelos de machine learning.

2.3.1 CREDITO BANCARIO EN EL SECTOR PRIVADO

El crédito bancario al sector bancario se define como el conjunto de los financiamientos otorgados por instituciones financieras formales a hogares y empresas para consumo, inversión y operatividad. De acuerdo con el World Bank (2024), el indicador es clave para determinar el crecimiento económico, dado que permite la reasignación eficiente de los recursos hacia la actividad productiva.

En honduras, el Banco Central lleva el control de la publicación de este indicador de forma estructural para evaluar el dinamismo financiero y el riesgo (Banco Central de Honduras, 2024a).

Para esta investigación el crédito se define como el saldo mensual de la cartera de préstamos otorgados por el sistema bancario hondureño, en términos nominales y obtenido de las estadísticas oficiales de Banco Central de Honduras. Esta variable es la variable dependiente principal de los modelos de predicción y con comportamiento es analizado en relación con la tasa de política monetaria y otras condiciones macrofinancieras.

Definición operativa: Para efectos de esta tesis, el crédito bancario se medirá como el **saldo mensual del crédito total al sector privado** reportado por el BCH (serie **EMF-AMCC-01, IndicadorId 549**), expresado en **millones de lempiras corrientes**. Para el modelado, se utilizará principalmente la transformación **logarítmica** del nivel: $Y_t = \ln(\text{Crédito}_t)$, y se evaluará su comportamiento en el periodo **2010-01 a 2025-12**, con **frecuencia mensual**.

2.3.2 TASA DE POLÍTICA MONETARIA (TPM)

La tasa de política monetaria es el principal instrumento utilizado por los bancos centrales para influir sobre las condiciones de liquidez, las tasas bancarias internas y las tasas bancarias activas y pasivas. El Fondo Monetario Internacional (2025) define esta como “precio de referencia” que orienta el costo del dinero en las economías. En el caso hondureño, la TPM es presentada por el Banco Central de Honduras como parte de un esquema de políticas monetarias y sus alteraciones impactan el costo financiero y la oferta del crédito (Banco Central de Honduras, 2025a).

Para esta investigación, la tasa de política monetaria se define como la tasa de referencia de estabilidad del Banco Central de Honduras, con frecuencia mensual, utilizada como variable explicativa fundamental para evaluar la transmisión de la política monetaria hacia el crédito bancario, su impacto fue analizado considerando rezagos y no linealidad.

Definición operativa: Para efectos de esta tesis, la TPM se medirá mediante la **serie mensual oficial** del BCH (serie **EM-TPM-01, IndicadorId 700**), en **porcentaje anual**. En la estimación se incorporará (i) en **nivel**, y (ii) en **rezagos mensuales** (por ejemplo, $TPM_{t-1}, TPM_{t-3}, TPM_{t-6}$) para capturar efectos retardados. En los modelos que lo requieran, se usará su representación en **términos decimales** (p.ej., $5.75\% = 0.0575$).

2.3.3 TRANSMISIÓN MONETARIA

La transmisión monetaria es el proceso mediante el cual los cambios en la tasa de política monetaria impactan a las tasas de interés y sucesivamente al crédito y la actividad económica (International Monetary Fund, 2024).

Sin embargo, en economías emergentes existen fricciones como concentración bancaria, informalidad y flujos en las remesas que termina generando transmisiones parciales o no lineales.

Para esta investigación, la transmisión de la política monetaria se tomará como el grado en que las variaciones en la TPM se reflejan en el volumen del crédito bancario observable, considerando rezagos temporales, asimetría y posibles cambios de régimen.

Definición operativa: Para efectos de esta tesis, la transmisión monetaria se operacionaliza como el **impacto estadístico de la TPM sobre el crédito bancario**, observado en la relación entre TPM_{t-k} y Y_t (crédito) para distintos **rezagos k** . Se evaluará mediante: (i) significancia y magnitud de coeficientes en modelos lineales (benchmark), y (ii) capacidad

predictiva incremental al incorporar TPM y rezagos en modelos ML (variación de RMSE/MAE/MAPE fuera de muestra).

2.3.4 NO LINEALIDAD MACROFINANCIERA

La no linealidad macrofinanciera hace relación al impacto en las economías donde las variables no son proporcionales en el tiempo. Estudios recientes muestran que el crecimiento en el crédito hace frente al cambios en regímenes o efectos externos corresponden a un umbral en esta investigación hacen frente al régimen del TPM (Avdjiev & Zeng, 2014; Balke, 2000; Gumata & Ndou, 2017).

En el contexto de esta investigación la no linealidad se define como la existencia de relaciones entre la tasa de política monetaria y el crédito bancario que no respondan de manera proporcional, constante o simétrica ante cambios en la tasa referencial.

Definición operativa: Para efectos de esta tesis, la no linealidad se medirá indirectamente mediante (i) el **deterioro del desempeño** de modelos lineales (ARIMA/VAR) frente a modelos ML y (ii) la presencia de **interacciones/efectos no proporcionales** capturados por algoritmos no lineales (Random Forest / XGBoost), evaluados por mejoras fuera de muestra y por herramientas de interpretación (p.ej., SHAP) que evidencien contribuciones variables según el contexto.

2.3.5 REZAGOS

Para esta investigación se define como el tiempo transcurrido entre una variación en la tasa de política monetaria y su impacto observable en el crédito bancario, medido en periodo mensuales. Los cuales pueden ser variables en el tiempo y diferentes en magnitud, lo que justifica el uso de modelos capaces de capturar dinámicas flexibles.

Definición operativa: Para efectos de esta tesis, los rezagos se medirán como **desplazamientos mensuales** de las variables explicativas y, cuando aplique, de la variable dependiente: $X_{t-1}, X_{t-3}, X_{t-6}, X_{t-12}$. Se construirán rezagos sistemáticos para TPM y demás covariables y se seleccionarán según desempeño predictivo y estabilidad del modelo (validación temporal).

2.3.6 MODELOS ECONOMÉTRICOS TRADICIONALES

Para esta investigación se define aquellos modelos con un enfoque lineal de series de tiempo que asumen relaciones estables, simétricas y proporcionales entre las variables macroeconómicas, tales como ARIMA o VAR lineales, utilizados como puntos de comparación a metodologías más flexibles.

Definición operativa: Para efectos de esta tesis, los modelos econométricos tradicionales se operacionalizan como el **benchmark lineal** estimado con la misma base mensual 2010–2025, principalmente mediante **ARIMA/SARIMAX** y/o **VAR lineal**. Su función operativa es generar pronósticos fuera de muestra del crédito y producir métricas (RMSE/MAE/MAPE) comparables con ML.

2.3.7 MACHINE LEARNING (ML)

Estos hacen referencia a un conjunto de métodos estadísticos y computacionales que permiten que estos modelos aprendan a partir de los datos, sin la suposición lineal o linealidad sino de los patrones sobre estos mismos.

En macroeconomía, los modelos de machine learning demuestran ser superiores a los modelos tradicionales en tareas como inflación, ciclos económicos y crecimiento del crédito (Bluwstein et al., 2021; Coulombe et al., 2020).

Para esta investigación, el machine learning se define como un conjunto de técnicas computacionales de aprendizaje supervisado utilizados para modelar y predecir comportamiento del crédito bancario a partir de las variables macroeconómicas, permitiendo capturar relaciones no lineales, interacciones complejas y patrones dinámicos en la dinámica de la transmisión monetaria hondureña.

Definición operativa: Para efectos de esta tesis, ML se medirá como el **conjunto de modelos supervisados de regresión** entrenados para pronosticar Y_t (crédito) utilizando TPM y variables macrofinancieras, incluyendo rezagos y transformaciones. Operativamente, el desempeño de ML se cuantificará mediante métricas fuera de muestra (RMSE/MAE/MAPE y, cuando corresponda, R^2 ajustado) y mediante interpretabilidad (SHAP) para identificar importancia de variables.

2.3.8 MODELOS DE ENSAMBLE (RANDOM FOREST Y XGBOOST)

Los modelos de ensamble hacen combinación de múltiples árboles de decisión para mejorar la precisión y estabilidad de los mismo.

- Random Forest: Estos se usan para reducir el ajuste utilizando el promedio de múltiples árboles independientes (Breiman, 2001a).
- XGBoost: es un algoritmo de gradient boosting que resulta eficiente para interacciones no lineales (Chen & Guestrin, 2016).

Estos modelos son usados en predicciones financieras por su capacidad de captar relaciones no lineales como ser tasas, inflación y crédito.

Definición operativa: Para efectos de esta tesis, Random Forest y XGBoost se medirán como **modelos entrenados** sobre el conjunto de entrenamiento temporal y evaluados en un bloque final de prueba. Su comparación se basará en métricas de pronóstico (RMSE/MAE/MAPE) y en interpretabilidad mediante SHAP para explicar contribuciones de TPM y demás variables.

2.3.9 SERIES DE TIEMPO MACROECONOMICAS

Hace referencia a una secuencia de observaciones macroeconómicas. Que en modelos predictivos se usan para analizar el rezago, tendencias y patrones en el tiempo. Cuando existen rezagos, régimen, shocks externos o no linealidad los modelos tradicionales como ARIMA muestran limitaciones (Hyndman & Athanasopoulos, 2018).

Definición operativa: Para efectos de esta tesis, las series de tiempo macroeconómicas se medirán como un **panel mensual integrado** (una fila por mes) con variables del BCH para 2010–2025. La estructura operativa del dataset será la matriz $(Y_t, X_{1t}, \dots, X_{kt})$ y sus rezagos, utilizada de forma consistente en econometría y ML.

2.3.10 INTERPRETABILIDAD EN ML (EXPLAINABLE AI - XAI)

Esta busca explicar el cómo y por qué en la toma de decisión de los modelos de ML. Herramientas como SHAP permiten identificar la contribución que tienen cada variable dentro de los modelos (Lundberg & Lee, 2017).

Definición operativa: Para efectos de esta tesis, la interpretabilidad se medirá mediante **valores SHAP** calculados sobre los modelos ML seleccionados como mejores por desempeño. Se

reportará: (i) ranking global de importancia, y (ii) evidencia de contribuciones de TPM y variables macrofinancieras por periodos del conjunto de prueba.

2.4 TEORÍAS DE SUSTENTO

2.4.1 TEORÍA DE LA INFORMACIÓN ASIMÉTRICA

La teoría de la información asimétrica se vale de la premisa de que, en los mercados de crédito, las personas que desean adquirir un préstamo conocen mejor el riesgo que las entidades bancarias. Cuando la tasa de interés sube los prestatarios de menor riesgo se retiran del mercado, mientras que los que mayor riesgo tienen se mantienen en él. Además, los solicitantes de préstamos una vez aprobadas los mismos tienden a tomar decisiones más arriesgadas que las entidades bancarias no pueden observar.

Stiglitz y Weiss (1981) afirman que bajo estos términos los bancos no ajustan las tasas sino la cantidad de crédito que otorgan. Esto se refiere que cuando hay una demanda solvente, los bancos pueden reaccionar el crédito en vez de subir las tasa, porque subir la tasa crediticia puede tener un impacto negativo empeorando la cartera y elevando el riesgo de incumplimiento.

Relevancia en esta investigación:

- Justifica que la variable dependiente sea el crédito total en el sector privado y no la tasas.
- Sustenta teóricamente que la respuesta del crédito ante la tasa de política monetaria no es proporcional o línea. Ante cambios en el TPM, los bancos cortan o endurecen los créditos en vez de trasladar a la tasa.
- Da validez a la hipótesis de no linealidad: una variación en el TPM puede impactar el crédito de distintas formas según riesgo, el ciclo o la demanda del crédito.

2.4.2 TEORÍA DE ACELERACIÓN FINANCIERO Y CICLO DEL CREDITO

La teoría del acelerador financiero plantea que los choques entre lo real y lo monetario se amplifican mediante el sistema financiero porque la relación entre el costo de financiamiento externo depende de los balances financiero de los prestatarios (aplazamiento, patrimonio).

Según Bernanke, Gertler y Gilchrist (1998) en su modelo en un deterioro del patrimonio de las empresas esto eleva las primas de financiamiento, reduce el crédito, desfavorece la inversión y la actividad real empresarial. De forma similar Kiyotaki y Moore (1997) señalan que, los activos aparte de servir como factores productivos, pequeñas variaciones pueden generar grandes fluctuaciones en el valor de los activos, crédito y producción generando ciclos del crédito.

Relevancia para esta investigación:

- Fundamenta que el TPM impacta al crédito no solo mediante “valor del dinero”, sino mediante valores colaterales, patrimonio y liquidez en el sistema.
- Refuerza los argumentos sobre la no linealidad entre el TPM y el crédito y la dependencia de los ciclos donde ante balances bajos un aumento en el TPM puede impactar proporcionalmente el crédito.
- Justifica el uso de Machine Learning para la captura de las interacciones complejas que existen entre indicadores como el TPM, inflación, tipo de cambio, PIB y crédito.

2.4.3 CANAL DE PRÉSTAMO BANCARIO Y TRANSMICIÓN BANCARIA

El canal de préstamos bancarios o bank lending channel en inglés hace énfasis que las políticas monetarias afectan al crédito no solo mediante la tasa de interés sino mediante la capacidad de estos para conceder préstamos. Este impacto se ve mayor reflejado en bancos pequeños con una limitada liquidez y poco acceso a fondos lo que obliga a estos a restringir su oferta de crédito.

Kashyap y Stein (2000) mediante el análisis de datos de bancos de Estados Unidos, muestran los efectos de la política monetaria sobre el crédito son mayores en bancos pequeños o con menos activos, lo que evidencia este canal.

Mientras que para economías en desarrollo, Mishra y Montiel (2013) argumentan que, dado la menor profundidad financiera, el oligopolio bancario y la dependencia del crédito bancario en el mercado, el canal de préstamos es el principal mecanismo de transmisión de la política monetaria, pero esto no hace que sea efectiva y genera heterogeneidad.

Relevancia para esta investigación:

- Refuerza el enfoque en el crédito bancario privado tiene coherencia con la transmisión monetaria en países como Honduras.
- Da cabida a la interpretación del impacto del TPM sobre el crédito bancario depende de otros indicadores como la concentración bancaria, el impacto de las remesas y las regulaciones, indicadores que pueden introducir no linealidad y cambios de régimen.
- Sustenta que el uso de Machine Learning para modelar el crédito puede capturar heterogeneidad en tiempo y posibles cambios en la forma de transmisión bancaria.

2.4.4 NO LINEALIDAD EN LA TRANSMISIÓN MONETARIA Y EN LAS RELACIONES MACROECONOMICAS

Esta teoría resalta que la transmisión monetaria no es constante, que depende del estado. Es decir que una misma variación en la tasa de la política puede tener diferentes efectos dependiendo del nivel de endeudamiento, el estrés financiero o regímenes macroeconómicos.

El estudio de Mishra y Montiel (2013) demuestran que los efectos de las políticas monetarias sobre el crédito pueden ser no lineales y persistentes, también muestra evidencia de un umbral y asimetría en economías emergentes como la hondureña. Al combinar esta literatura con la teoría de acelerador financiero y las restricciones del crédito, se fortalece el vínculo entre TPM, crédito y actividad están sujetos a cambios de regímenes y existencia de fenómenos de amplificación.

Relevancia para la tesis:

- Sustenta el argumento de que los modelos lineales (ARIMA, VAR lineales) no son suficientes para capturar las dinámicas reales del TPM y el crédito en Honduras.
- El uso de modelos de machine learning (Random Forest, XGBoost) no es por una moda técnica, sino la respuesta metodológica sustentada en la evidencia teórica y empírica sobre la no linealidad y dependencia.

2.4.5 APRENDIZAJE AUTOMÁTICO CON ÉNFASIS A INFERENCIA EMPIRICAS (APRENDIZAJE ESTADÍSTICO)

El aprendizaje estadístico tiene como objetivo una función $F(X)$ que se relaciona con un conjunto de predictores X (TPM, tipo de cambio, inflación, PIB) con una respuesta Y (crédito bancario), minimizando el error de predicción fuera de la muestra. Hastie, Tibshirani y Friedman (2009) formalizaron este demostrado que los modelos no lineales y de ensamble (árboles, boosting, Random Forest, redes neuronales) son adecuados cuando las relaciones que existen entre las variables son complejas y no lineales.

Breiman (2001b) categoriza dos culturas, cultura de los modelos de datos (regresión lineal, VAR) y cultura algorítmica (árboles, Random Forest, redes neuronales) señalando que cuando las verdaderas dinámicas son complejas o desconocidas los modelos algorítmicos suelen ser superiores.

Relevancia para la investigación:

- Sustenta el uso de machine learning y no modelos lineales dado el contexto de la investigación.
- Sustentan el propósito macrofinanciero de mejorar el pronóstico del crédito mediante TPM y sitúa la misma dentro de la cultura algorítmica.

2.5 ANTECEDENTES DE METODOLOGÍAS UTILIZADAS

Los académicos que analizan la relación entre la política monetaria y el crédito bancaria han utilizado diferentes metodologías para explicar y pronosticar el comportamiento del crédito. En las literaturas se observa una evolución clara sobre la evaluación de la econometría desde un enfoque lineal hacia uno no lineal y en más recientes, hacia técnicas de machine learning motivadas por evidencia que en economías emergentes se pueden presentar cambios de régimen, asimetría y no linealidad que afectan el desempeño de modelos lineales. En este sentido, el análisis metodológico del estado del arte permite observar que la discusión ya no gira únicamente en torno a qué modelo “predice más”, sino también a bajo qué supuestos lo hace, con qué nivel de interpretabilidad y bajo qué criterio de validación debe ser juzgado (Coulombe et al., 2020; Mishra & Montiel, 2013; Stock & Watson, 2012).

En la tradición econométrica, modelos lineales como ARIMA, VAR y sus variantes han sido utilizadas ampliamente como puntos de referencia metodológica. Su principal fortaleza radica en la parsimonia, la claridad estructural y la facilidad con la que permite interpretar las relaciones promedio que existen entre el crédito y la actividad económica. Sin embargo las mismas investigaciones señalan la debilidad ante choques, inestabilidad estructural y repuestas heterogéneas en las variables de estudio. La transmisión monetaria dentro de economías en desarrollo suele ser más débil, menos marcadas que en economías avanzadas lo que limita la capacidad de los modelos para captar la realidad de los sistemas (Mishra & Montiel, 2013). De igual manera el desempeño de los modelos VAR se ve mermado en cambios de regímenes y lo que hace que los modelos clásicos pierdan precisión ante entornos de alta incertidumbre (Araujo & Gaglianone, 2023; Kilian & Lütkepohl, 2017).

Como respuestas a estas limitantes, las literaturas recientes han incorporado métodos de machine learning para abordar estos problemas desde un paradigma orientado al desempeño predictivo de los modelos. Modelos como Random Forest, XGBoost, Lasso y redes neuronales han demostrado capacidad para capturar relaciones complejas, interacciones no explícitas y patrones no lineales sin requerir una especificación funcional rígida. Específicamente, la literatura indica que estos métodos tienen el potencial de ser útiles para analizar el aumento del crédito, el riesgo sistémico y la utilización de modelos regularizados como Lasso en situaciones con colinealidad elevada y muestras de tamaño medio. Sin embargo, estas técnicas también tienen sus limitaciones; por ejemplo, las redes profundas, que son modelos más complejos, a menudo requieren de muestras más grandes de las que se encuentran en numerosas aplicaciones macroeconómicas. También pueden sobre ajustarse si no se evalúan con una validación temporal rigurosa, lo que les da un aspecto de superioridad que no siempre se mantiene fuera de la muestra (Araujo & Gaglianone, 2023; Coulombe et al., 2020; Fischer & Krauss, 2018; Sadhwani et al., 2021).

Por lo tanto, la evaluación de las metodologías empleadas en la literatura conduce a una conclusión significativa: no hay una familia metodológica que sea superior en todos los casos, sino métodos que son más o menos apropiados dependiendo del tipo de problema, el tamaño de la muestra, la estabilidad estructural del fenómeno y el criterio de evaluación. Los modelos no lineales tradicionales proporcionan estructura para fenómenos que dependen del estado, los

modelos lineales continúan siendo importantes como benchmarks y herramientas de lectura promedio; por su parte, aunque requieren más en términos de validación e interpretación, los modelos de aprendizaje automático brindan flexibilidad y capacidad predictiva. Por eso, la discusión metodológica más estricta no consiste en reemplazar una tradición por otra, sino en analizarlas mediante criterios uniformes y relevantes para el contexto.

2.6 ANTECEDENTES METODOLÓGICOS

Las literaturas anteriores toman un enfoque cuantitativo debido a la naturaleza medible, continua y sistemática de los indicadores macrofinancieros analizados. El análisis cuantitativo es el método predominante en investigaciones que se centran en transmisión monetaria, predicciones macroeconómicas y evaluaciones de modelos estadísticos y macrofinancieros (Coulombe et al., 2020; Stock & Watson, 2012).

Respecto a la metodología, los métodos no experimentales, correlacionales, explicativos y predictivos son la principal base de los estudios revisados en la literatura. No es experimental, ya que los autores no alteran las variables, sino que examinan su comportamiento a lo largo de la historia utilizando información proporcionada por entidades multilaterales, bancos centrales o oficinas de estadística. Es correlacional porque analiza las conexiones entre el crédito y los factores macrofinancieros. Es explicativo porque trata de entender la manera en que el entorno macroeconómico, las tasas de interés o la política monetaria afectan el desarrollo del crédito. Y es predictivo, ya que una parte importante de la literatura actual pretende predecir los valores futuros del crédito y averiguar qué modelo lo realiza mejor bajo validación fuera de muestra (Mishra & Montiel, 2013; Shmueli, 2010).

En lo que se refiere al diseño, es evidente que el predominio es longitudinal de series temporales. Dado que la dinámica del crédito y la transmisión monetaria no se pueden analizar apropiadamente en cortes transversales independientes, este diseño es coherente con el carácter del problema. Es necesario examinar el camino que siguen las variables a través del tiempo, incorporar rezagos, detectar persistencia y comparar cambios de régimen. Por lo tanto, la mayor parte de las investigaciones significativas en este ámbito utilizan esquemas longitudinales fundamentados en observaciones trimestrales o mensuales, que se complementan con pruebas de

validación temporal y estacionariedad (Hyndman & Athanasopoulos, 2018; Kilian & Lütkepohl, 2017).

La literatura más robusta hace una distinción explícita entre estos tres niveles: mantiene una perspectiva cuantitativa, elabora métodos no experimentales para propósitos predictivos y explicativos, y trabaja con diseños longitudinales de series temporales. Por esta razón, el progreso metodológico reciente no ha implicado un cambio de perspectiva o la renuncia al diseño longitudinal, sino una modificación en la manera de comparar modelos, validar su rendimiento e interpretar sus resultados.

2.7 ENFOQUES, MÉTODOS Y DISEÑO

Las literaturas revisadas sobre transmisión monetaria y pronósticos macrofinancieros convergen en un enfoque **cuantitativo** por una razón práctica: el fenómeno que se observa y mide son series numéricas y el desempeño metodológico se acopla a métricas replicables de error y ajustes. Se evidencia que los estudios comparan modelos bajo criterios cuantificables y estadísticos, lo que es consistente con un enfoque macroeconómico y de series de tiempo (Coulombe et al., 2020; Hyndman & Athanasopoulos, 2018; Stock & Watson, 2012).

Con respecto al método, los antecedentes se sostienen mayoritariamente en un marco **no experimental** porque las variables financieras no son manipuladas por los investigadores; se analizan los fenómenos históricos observados. A partir de esto el método dominante es **correlacional explicativo con énfasis predictivo**, donde el énfasis está en dos planos: estimar relaciones y dinámicas y evaluar la capacidad de pronóstico (Coulombe et al., 2020; Mishra & Montiel, 2013; Stock & Watson, 2012).

En términos del diseño, las literaturas revisadas estructuran las investigaciones como **longitudinales** de series de tiempo dado a la naturaleza de las variables macrofinancieras y su posibles retrasos y dependencia a los ciclos. Por eso las literaturas trabajan con observaciones repetidas mensuales o trimestrales, construyen rezagos y evalúan su estabilidad en el tiempo (Kilian & Lütkepohl, 2017). Finalmente, literaturas recientes legitiman el diseño **predictivo** como objetivo principal cuando la finalidad es anticipar valores futuros como el crédito, este punto es clave porque los investigadores hacen utilización de técnicas de machine learning no como moda técnica sino como una respuesta a evidencia de no linealidad, interacciones y cambios de régimen

que reducen la efectividad de los modelos lineales (Coulombe et al., 2020; Hastie et al., 2009; Shmueli, 2010; Stock & Watson, 2012).

2.8 ANÁLISIS CRÍTICO DE METODOLOGÍAS

Aunque existe una consistente coincidencia en las literaturas revisadas en cuanto a un enfoque cuantitativo longitudinal, el análisis crítico evidencia que la diferencia entre un resultado convincente y uno frágil no depende del modelo elegido sino de las decisiones metodológicas correctas: cómo validar, cómo tratar la estabilidad temporal, cómo representar la no linealidad y cómo interpretar los modelos por lo cual se han revisado las literaturas para encontrar debilidades en estas frente al tema de estudio de esta investigación.

La primera debilidad es que se mantengan los estudios que se basan demasiado en suposiciones de estabilidad estructural y linealidad. A pesar de que los modelos VAR, ARIMA y sus variantes son totalmente válidos como referencia, varios estudios los utilizan como si fueran suficientes para representar sistemas en los que ocurren alteraciones regulatorias, heterogeneidad institucional, choques externos y reacciones asimétricas del crédito. El problema con los métodos no es la utilización de modelos lineales, sino el hecho de que se asuma que estos describen apropiadamente relaciones que la literatura misma ha evidenciado como inestables o dependientes del régimen (Kilian & Lütkepohl, 2017; Mishra & Montiel, 2013).

Una segunda debilidad se presenta en las investigaciones que utilizan modelos no lineales convencionales. Estos modelos constituyen un progreso significativo en comparación con la linealidad estricta, pero siguen estableciendo de antemano la forma específica de la no linealidad. Esto puede ser problemático en términos metodológicos en situaciones donde la dinámica del crédito está influenciada simultáneamente por choques cambiarios, cambios regulatorios, fricciones monetarias y alteraciones en la estructura del sistema bancario. En estas situaciones, puede que una única estructura de transición o umbral no sea suficiente para capturar la verdadera complejidad del fenómeno (Auerbach & Gorodnichenko, 2012; Avdjiev & Zeng, 2014).

Una tercera debilidad, que es particularmente relevante en la literatura más reciente, es la falta de una evaluación predictiva adecuada. Algunos de los estudios comparativos continúan basándose en métricas de ajuste dentro de la muestra o en esquemas de validación que no tienen en cuenta el orden cronológico de los datos. Este problema es crucial en el aprendizaje automático,

ya que tiene la capacidad de aumentar artificialmente el rendimiento de algoritmos flexibles y generar una percepción de superioridad que no se mantiene en situaciones reales de pronóstico. La literatura más reciente ha dejado claro que la comparación de modelos pierde su validez externa sin una validación temporal estricta (Coulombe et al., 2020; Sadhwani et al., 2021).

En resumen, el análisis crítico de los métodos revisados indica que la elección metodológica más sólida no es adoptar una técnica a priori, sino contrastar modelos lineales y no lineales con técnicas de machine learning utilizando protocolos homogéneos de validación, prestando al mismo tiempo atención a la parsimonia, la interpretabilidad y el contexto estructural del fenómeno bajo estudio.

2.9 HERRAMIENTAS Y SOFTWARE

Para el procesamiento, análisis y modelación de los indicadores del BCH se requiere de herramientas analíticas capaces de manejar series de tiempo, ejecutar modelos estadísticos y aplicar modelos de machine learning de forma que sea reproducible y transparente con estas mismas. Tomando en cuenta que las fuentes de los datos son mediante la API del Banco Central de Honduras la herramienta debe tener la capacidad de extraer, transformar y modelación de estos de forma óptima. Pero estas no son las únicas para esta investigación se consideraron varios ejes como: Planificación y control del avance, analítica de datos, reproducibilidad y control de versiones y documentación / redacción y presentación de resultados. La selección se realizó considerando el costo, curva de aprendizaje y la compatibilidad con el flujo de reproducibilidad API – ETL – modelo – validación – reporte.

TABLA 3 Herramientas para análisis de datos

Criterio	Python	R	KNIME
Enfoque principal	Lenguaje de programación general con orientación a ciencia de datos y machine learning.	Lenguaje estadístico especializado en análisis econométrico y series de tiempo.	Plataforma visual de analítica de datos basada en flujos de trabajo sin código.
Series de tiempo macroeconómicas	Amplio soporte con pandas, statsmodels y scikit-learn para ARIMA, VAR y modelos híbridos.	Alta especialización con paquetes como forecast, vars y tsibble.	Soporte mediante nodos de series de tiempo, con menor flexibilidad econométrica.

Machine Learning	Ecosistema maduro (scikit-learn, XGBoost, LightGBM, PyTorch).	Soporte sólido mediante caret y mlr3, con menor adopción en ML macrofinanciero.	ML accesible mediante nodos visuales, limitado para arquitecturas avanzadas.
Integración con API oficial BCH	Alta capacidad para consumir API REST y automatizar flujos de datos oficiales.	Integración posible pero menos directa que Python.	Integración limitada; requiere extensiones o scripting externo.
Reproducibilidad	Alta mediante Jupyter Notebooks y control de versiones.	Alta mediante scripts reproducibles en RStudio.	Media; depende de documentación de flujos visuales.
Alineación con la tesis	Óptima para integrar econometría tradicional y ML con datos del BCH.	Complementaria para validación econométrica.	Secundaria para fines exploratorios.

Fuente: elaboración propia con base en (Berthold et al., 2008; Hyndman & Athanasopoulos, 2018; McKinney, 2022).

TABLA 4 Herramientas para reproducibilidad, control de versiones y gestión del código

Herramienta	Descripción	Ventajas	Desventajas	Costo	URL	Recomendación para la investigación
Git	Control de versiones para código, scripts, y cambios del proyecto.	Trazabilidad total; rollback; evidencia de evolución del trabajo; soporte académico a reproducibilidad.	Curva inicial de aprendizaje.	Gratis.	https://git-scm.com	Seleccionado. Base para garantizar trazabilidad y control de cambios en scripts y resultados.
GitHub	Repositorio remoto + issues/proyectos para seguimiento y respaldo.	Respaldo; auditoría; colaboración; Issues para registrar decisiones/metodología.	Requiere cuidado con datos sensibles; si es público, debe anonimizarse lo necesario.	Freemium.	https://github.com	Recomendado (repo privado o público según política). Complementa Git con respaldo y trazabilidad.
Conda / venv	Gestión de entornos y dependencias.	Reproduce el entorno exacto; evita “funciona en mi máquina”; soporta replicación del estudio.	Requiere documentar requirements/environment.	Gratis.	https://docs.conda.io	Recomendado. Fundamental para reproducibilidad de modelos ML y econométricos.
VS Code	Editor/IDE para scripts, notebooks y control de Git.	Ligero; integración Git; extensiones Python; buena productividad.	Preferencia personal; no obligatorio.	Gratis.	https://code.visualstudio.com	Seleccionado. Entorno de trabajo principal para desarrollar el pipeline. La reproducibilidad se documenta con requirements.txt y scripts versionados en Git.

Fuente: elaboración propia.

TABLA 5 Herramientas para redacción académica, referencias, diagramas y presentación

Herramienta	Descripción	Ventajas	Desventajas	Costo	URL	Recomendación para la investigación
Microsoft Word	Redacción final con formato institucional.	Estándar universitario; estilos; compatibilidad; control de formato.	Puede desordenarse si no se usan estilos/plantilla.	Pago.	https://www.microsoft.com/microsoft-365/word	Seleccionado para el documento final de tesis.
Zotero	Gestor de referencias y citas (APA/IEEE).	Reduce errores de citación; biblioteca PDF; plugin para Word; estilo consistente.	Requiere configurar estilos y metadatos.	Gratis.	https://www.zotero.org	Seleccionado para asegurar consistencia bibliográfica.
diagrams.net (draw.io)	Diagramas (metodología, flujo ETL, arquitectura).	Gratis; exporta alta resolución; fácil de usar.	Diseño “básico” si no se usan plantillas.	Gratis.	https://www.diagrams.net	Seleccionado para figuras (flujo de datos, arquitectura analítica).
PowerPoint	Presentación de resultados (defensa).	Estándar; exportación limpia; visuales claras.	Requiere diseño consistente para tesis.	Pago.	https://www.microsoft.com/microsoft-365/powerpoint	Recomendado para defensa y resumen visual de resultados.

Fuente: elaboración propia.

Síntesis de selección Python (en visual code) se seleccionó como plataforma principal para ETL de los datos del BCH y modelado econométrico y machine learning, Knime como apoyo en contrastes estadísticos puntuales. Para la trazabilidad y auditoria del desarrollo se emplea Git/Github (control de versiones y respaldo). La redacción y referencia se gestionan en Word y Zotero y los diagramas se elaboran en Lucidchart.

La selección de Python como plataforma principal responde a tres criterios académicamente fundamentados. Primero, la integración del pipeline completo: Python permite ejecutar en un mismo entorno la extracción desde la API del BCH, la transformación ETL, la estimación de benchmarks econométricos (statsmodels) y el entrenamiento de modelos ML (scikit-learn), garantizando trazabilidad sin transferencia de datos entre plataformas. Segundo, la implementación directa de validación walk-forward mediante TimeSeriesSplit. Tercero, la biblioteca shap integrada con scikit-learn.

2.10 MARCO LEGAL

El marco legal bajo el que se rige el sistema financiero hondureño nos permite comprender los elementos fundamentales bajo los cuales se rigen, gestionan las tasas activas y pasivas los bancos hondureños y como son las condiciones bajo las que funcionan la tasa de política monetaria (TPM), la calidad de los datos disponibles y las prácticas de supervisión prudenciales. Con este buscamos las regulaciones nacionales e internacionales que rigen la naturaleza de las series económicas de este estudio.

2.10.1 MARCO INTERNACIONAL

Aunque Honduras no adopta formalmente todos los estándares internacionales, muchos lineamientos globales influyen en su regulación, especialmente en materia de estabilidad financiera, gestión del riesgo crediticio y transparencia de datos. El sistema financiero opera en un entorno donde Basilea III y los enfoques prudenciales se usan como referencia en la gestión de solvencia y riesgo. Particularmente en los requerimientos de capital de mayor calidad (CET1) y los colchones de capital son relevantes porque generan restricciones no lineales.

TABLA 6 Marco legal internacional relevante

Estándar / marco	Organismo emisor	Descripción	Relevancia para la tesis
Basilea III: marco regulatorio global para bancos más resilientes	Comité de Basilea de Supervisión Bancaria (BCBS) – BIS	Estándares prudenciales sobre capital y liquidez (colchones de capital, métricas de liquidez).	Cambios regulatorios en capital/liquidez alteran oferta de crédito y pueden inducir asimetrías.
Colchón de conservación de capital (CCB) y colchón de capital anticíclico (CCyB)	BCBS – BIS	Componentes de Basilea III: el CCB busca absorber pérdidas; el CCyB se activa para mitigar el ciclo crediticio.	Justifica que el crédito no responde lineal: en fases de expansión/estrés, la banca ajusta cartera y estándares, lo que agrega no linealidad y dependencia del estado.
BCBS 239: Principios para la agregación efectiva de datos de riesgo y reporte de riesgo	BCBS – BIS	Principios para que los bancos consoliden datos de riesgo de forma consistente, oportuna y auditable.	Cambios en prácticas de medición/reportes pueden afectar series y comparabilidad.
Principios Básicos para una Supervisión Bancaria Eficaz.	BCBS – BIS	Principios internacionales para marcos de supervisión (gobernanza, gestión de riesgos, capital, provisiones, etc.).	En economías emergentes la transmisión monetaria vía crédito depende de supervisión, provisiones y reglas prudenciales agregando heterogeneidad en el canal del crédito.
Manual y Guía de Compilación de Estadísticas Monetarias y Financieras (2016)	Fondo Monetario Internacional (FMI)	Estándar internacional para definir y compilar estadísticas monetarias/financieras.	Las variables deben provenir de series con definiciones y prácticas consistentes; fortalece el “porqué” de usar fuentes oficiales.
Normas Especiales de Divulgación de Datos (SDDS / e-GDDS)	FMI	Marcos para difusión de datos macroeconómicos con periodicidad, calidad y transparencia.	Sustenta el uso de series oficiales y la trazabilidad; además ayuda a justificar por qué las series tienen frecuencia mensual y estándares de publicación.

Fuente: elaboración propia con base en (Hsu et al., 2025; International Monetary Fund, 2008, 2017; Repullo & Saurina, 2011).

2.10.2 MARCO NACIONAL (HONDURAS)

En el marco regulatorio hondureño tenemos reglas que establecen como opera la intermediación financiera, como los bancos reportan información y clasifican el riesgo de crédito. Esto permite tener una fuente de información confiables y contextualizada a través del BCH.

TABLA 7 Marco legal y regulatorio nacional

Estándar/Marco	Entidad emisora	Descripción	Relevancia en la tesis
Marco legal de autoridad monetaria y regulación financiera	Estado de Honduras	Establece el rol del BCH y el marco general del sistema financiero (autoridad, objetivos, estabilidad).	Sustenta el papel de la TPM y la estabilidad financiera como objetivos que condicionan transmisión y crédito.
Definición y rol de la TPM	Banco Central de Honduras (BCH)	La TPM es la tasa fijada por el BCH y referencia de condiciones monetarias.	Fundamenta operativamente la variable TPM como explicativa central (y su transmisión con rezagos).
Norma para evaluación y clasificación de cartera crediticia (Circular CNBS No.003/2022)	CNBS	Establece criterios de riesgo, categorías de cartera y requerimientos de provisiones.	Puede generar no linealidad: provisiones y reclasificaciones inducen cambios discretos en oferta de crédito ante estrés/riesgo.
Ley de Transparencia y Acceso a la Información Pública (LAIP) – Decreto 170-2006	Estado de Honduras / IAIP	Regula el derecho de acceso a información pública y obligaciones de transparencia/rendición de cuentas.	Sustenta el principio de publicidad y acceso a información pública, lo cual fortalece la justificación del uso de series oficiales y la exigencia de transparencia (documentación de fuentes, trazabilidad y disponibilidad).
Términos y condiciones de uso del portal/API del BCH	Banco Central de Honduras	Portal institucional para acceso a datos/servicios del BCH vía Web-API, con flujo de registro/gestión de acceso.	Define reglas para uso del portal (p. ej., aspectos de acceso/condiciones). En la tesis, se vincula a gobernanza del dato, cumplimiento y uso responsable de la fuente oficial para reproducibilidad.

Fuente: elaboración propia con base en (Banco Central de Honduras, 2025b; Comisión Nacional de Bancos y Seguros, 2022; Congreso Nacional de Honduras, 2006; Ley Del Banco Central De Honduras, 2016; Ley Del Sistema Financiero, 2004).

CAPÍTULO III. METODOLÓGIA DE INVESTIGACIÓN

3.1 CONGRUENCIA METODOLÓGICA

El desarrollo metodológico de esta investigación se fundamenta en la coherencia explícita entre el problema de investigación, las preguntas formuladas bajo el esquema PICO, los objetivos definidos en formato SMART y las características de los datos disponibles para el caso hondureño. Como se expuso en el Capítulo I, el problema central radica en la limitada capacidad de los modelos econométricos lineales tradicionales para predecir el comportamiento del crédito bancario agregado al sector privado a partir de la Tasa de Política Monetaria y otros determinantes macroeconómicos, durante el período 2010–2025, en una economía emergente con relaciones potencialmente no lineales, rezagos y efectos asimétricos entre sus variables financieras y reales (Hernández Sampieri et al., 2006).

En coherencia con ello, las preguntas de investigación se orientan a comparar rigurosamente el desempeño predictivo de distintos modelos de *machine learning* frente a un modelo econométrico lineal de referencia en la predicción del crédito bancario hondureño, así como a evaluar el aporte explicativo de variables como la Tasa de Política Monetaria, la inflación, el crecimiento del producto y otros indicadores macrofinancieros relevantes. Los objetivos generales y específicos, formulados en formato SMART, traducen estas preguntas en metas observables y medibles, al establecer umbrales concretos de desempeño (reducciones porcentuales en el RMSE y niveles mínimos de ajuste mediante *R*-cuadrado ajustado) en un horizonte definido para el período 2010–2025 y utilizando datos oficiales del Banco Central de Honduras.

A partir de esta problematización, la investigación adopta un enfoque cuantitativo de alcance explicativo y carácter predictivo, basado en datos secundarios de frecuencia mensual. La variable dependiente corresponde al crédito bancario agregado al sector privado, mientras que las variables explicativas incluyen indicadores monetarios, reales y de precios que la literatura económica y financiera reconoce como determinantes del crédito, tales como la Tasa de Política Monetaria, las tasas de interés activas y pasivas, el índice de precios al consumidor y variables de actividad económica. La elección de modelos de *machine learning* no se concibe como una decisión meramente

tecnológica, sino como una respuesta metodológica a la hipótesis de que la relación entre estas variables es compleja y no estrictamente lineal, lo cual limita el poder predictivo de los modelos lineales convencionales.

Esta lógica de coherencia se desarrolla en cuatro componentes centrales que estructuran el presente capítulo. En la Sección [3.1.1](#) se presenta la matriz metodológica, que hace explícita la trazabilidad entre el problema, las preguntas PICO, los objetivos SMART, el enfoque cuantitativo, el tipo y el diseño de la investigación, las fuentes de datos y los indicadores con los que se evaluará el desempeño de los modelos. En la Sección [3.1.2](#) se detalla el esquema de variables, donde se clasifican en dependiente, independientes y derivadas (por ejemplo, tasas de variación, rezagos o ajustes por inflación), asegurando su consistencia con el marco teórico y con las necesidades del modelado predictivo. La Sección [3.1.3](#) presenta la operacionalización de las variables, traduciendo cada constructo en indicadores observables con su unidad de medida, frecuencia, fuente y escala de análisis. Finalmente, en la Sección [3.1.4](#) se formulan las hipótesis nula y alternativa que serán sometidas a contraste empírico respecto a la superioridad predictiva de los modelos de *machine learning* frente a los modelos econométricos lineales tradicionales.

3.1.1 MATRIZ METODOLÓGICA

La matriz metodológica explicita la congruencia vertical entre el problema de investigación, la pregunta general formulada bajo el esquema PICO, el objetivo general definido en formato SMART y las decisiones metodológicas adoptadas. En ella se sintetizan el fenómeno de estudio, el diseño de investigación, la unidad de análisis, las fuentes de datos, las variables incluidas y los indicadores que permitirán comparar el desempeño predictivo entre el modelo econométrico de referencia y los modelos de aprendizaje automático.

Asimismo, la matriz incorpora el criterio de evaluación fuera de muestra mediante partición cronológica y el uso de métricas de error (RMSE, MAE, MAPE) y medidas de ajuste cuando sean aplicables (R^2 ajustado). Estas decisiones permiten vincular los objetivos del estudio con el procedimiento de entrenamiento, validación y comparación de modelos.

TABLA 8 Matriz metodológica del estudio

Título de la investigación	Objetivos de Investigación		Variables
	General	Específicos	
Predicción del crédito bancario hondureño mediante modelos de machine learning basados en la Tasa de Política Monetaria (2010–2025)	Desarrollar un modelo de Machine Learning para pronosticar el crédito bancario agregado hondureño usando el TPM y variables macroeconómicas oficiales del BCH, alcanzando un R^2 ajustado > 0.85 y/o un RMS < 5% en el conjunto de pruebas fuera de la muestra, mediante el entrenamiento, ajuste y validación temporal con datos mensuales disponibles, para disponer de una herramienta predictiva más robusta para el análisis macrofinanciero y de riesgo sistemático, utilizando el periodo 2010-2025 como horizonte de estudio.	Establecer las variables macroeconómicas y financieras que se asocian con el comportamiento del crédito bancario, construyendo una base mensual integrada 2010-01 a 2025-08 a partir de series oficiales del BCH; incluyendo limpieza, alineación temporal y transformaciones/rezagos definidos.	Y: Crédito total al sector privado (BCH EMF-AMCC-01, IndicadorId 549; mensual). X1: Tasa de Política Monetaria (BCH EM-TPM-01, IndicadorId 700; mensual). Transformación base: $\log(Y)$ y rezagos de X1 ($k=1,3,6,12$), según desempeño.
		Medir el rendimiento predictivo de modelos econométricos lineales de referencia frente a al menos dos modelos de machine learning (regresión regularizada, Random Forest, XGBoost o redes neuronales), usando un esquema de entrenamiento/prueba fuera de muestra que respete el orden temporal, y verificando mejoras en métricas de error.	X2: Tasa de interés activa MN (BCH EMF-TI-01, IndicadorId 580; mensual). X3: Tasa pasiva de ahorro MN (BCH EMF-TI-01, IndicadorId 582; mensual). X4: Tipo de cambio nominal de venta (BCH EC-TCN-01, IndicadorId 620; diario agregado mensual). X5: Inflación interanual IPC (BCH EP-IPC-01, IndicadorId 609; mensual).
		Interpretar la contribución de la TPM y demás variables explicativas en el modelo de machine learning con mejor desempeño mediante técnicas de interpretabilidad (SHAP), a fin de traducir los resultados en implicaciones para la transmisión monetaria y el monitoreo macrofinanciero.	Modelos comparados: Benchmark lineal (SARIMAX/VAR lineal) vs. ML (Lasso/Elastic Net, Random Forest, XGBoost). Indicadores de desempeño fuera de muestra: RMSE, MAE, MAPE y R^2 ajustado. Interpretabilidad: valores SHAP para importancia global.

Fuente: Elaboración propia con base en el análisis metodológico del estudio.

3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO

El esquema de variables del estudio explicita la relación funcional que se analiza entre la variable dependiente (crédito bancario agregado al sector privado) y un conjunto de variables explicativas macrofinancieras vinculadas al canal de transmisión monetaria. En términos conceptuales, se plantea que el crédito Y_t responde a cambios en la postura monetaria y en las condiciones financieras y de precios, representadas por la Tasa de Política Monetaria (TPM), las tasas de interés activas y pasivas, la inflación y el tipo de cambio.

De manera general, la relación se resume como:

$$Y_t = f(\text{TPM}_t, i_t^{\text{activa}}, i_t^{\text{pasiva}}, \pi_t, \text{TC}_t) + \text{dinamica temporal (rezagos)}$$

Donde:

- t : mes calendario (unidad temporal de análisis).
- Y_t : Crédito total al sector privado en el mes t (variable dependiente).
- TPM_t : Tasa de política monetaria en el mes t .
- i_t^{activa} : Tasa de interés activa en moneda nacional en el mes t .
- i_t^{pasiva} : Tasa de interés pasiva de ahorro en moneda nacional en el mes t .
- π_t : Inflación interanual del IPC en el mes t .
- TC_t : tipo de cambio nominal de venta (L/USD) en el mes t .
- $f(\cdot)$: relación funcional entre el crédito y los determinantes macrofinancieros.
- Dinámica temporal (rezagos): inclusión explícita de información pasada, para capturar persistencia del crédito y retardos en la transmisión monetaria.

Donde los rezagos se incorporan debido a que los efectos de política monetaria y condiciones financieras sobre el crédito suelen materializarse con retardos. Operativamente, todas las series se integran a una frecuencia mensual para conformar una matriz temporal consistente (una fila por mes) utilizada en la estimación econométrica y en el entrenamiento de modelos de aprendizaje automático.

Además, el esquema se define con un criterio de trazabilidad y replicabilidad: cada variable del modelo se vincula de manera explícita con su serie oficial del BCH (Serie/Indicador), su unidad

de medida y su frecuencia de publicación, de forma que cualquier lector pueda reconstruir el conjunto de datos a partir de la misma fuente. Dado que algunas series pueden publicarse con frecuencias distintas (el tipo de cambio), se establece una regla única de armonización temporal para garantizar comparabilidad: todas las variables se convierten a una frecuencia mensual común y se valida que cada mes tenga un único valor por variable antes del modelado.

Esta decisión elimina inconsistencias por desalineación de fechas, reduce el riesgo de sesgo por mezcla de frecuencias y asegura que el desempeño de los modelos se evalúe con insumos homogéneos. En consecuencia, el esquema no solo “lista” variables, sino que fija el marco operativo que guía la construcción del dataset, la incorporación de rezagos y la evaluación predictiva respetando el orden temporal.

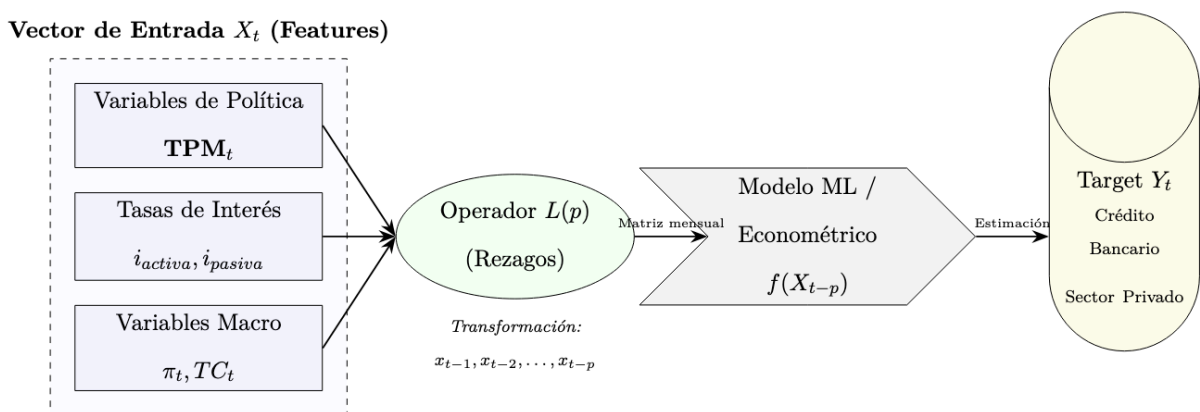


Ilustración 2 Diagrama del esquema de variables

Fuente: Elaboración propia con base en datos de la API del Banco Central de Honduras (BCH, 2025).

En la Tabla se sintetiza el rol de cada variable en el modelo, su código oficial en el BCH, su descripción y naturaleza estadística.

TABLA 9 Esquema de variables del estudio

Variable	Descripción	Serie/Indicador BCH	Unidad/Frecuencia
Crédito total al sector privado (Y)	Variable dependiente. Representa el saldo de crédito al sector privado del sistema financiero.	EMF-AMCC-01/Indicador 549	Lempiras; mensual
TPM mensual (X1)	Variable explicativa principal. Instrumento de	EM-TPM-01/Indicador 700	% anual; mensual

Variable	Descripción	Serie/Indicador BCH	Unidad/Frecuencia
	política monetaria asociado al costo de liquidez.		
Tasa activa en moneda nacional (X2)	Variable explicativa. Proxy del costo del crédito (condiciones de financiamiento).	EMF-TI-01/Indicador 580	% anual; mensual
Tasa pasiva de ahorro en moneda nacional (X3)	Variable explicativa. Proxy del costo de fondeo y atractivo del ahorro.	EMF-TI-01/Indicador 582	% anual; mensual
Tipo de cambio nominal de venta (X4)	Variable explicativa. Condición externa que afecta precios relativos, expectativas y condiciones financieras.	EC-TCN-01/Indicador 620	L/USD; diario
Inflación interanual (X5)	Variable explicativa. Entorno de precios que influye en tasas reales y demanda de crédito.	EP-IPC-01/Indicador 609	% interanual; mensual

Fuente: Elaboración propia con base en datos de la API del Banco Central de Honduras (BCH, 2025).

3.1.3 MATRIZ DE OPERACIONALIZACIÓN DE LAS VARIABLES

La matriz de operacionalización traduce las variables conceptuales del estudio en indicadores observables y replicables, precisando (i) el campo exacto utilizado en cada archivo (columna Valor), (ii) un protocolo uniforme de preprocesamiento (conversión de Fecha a formato calendario, ordenamiento cronológico, estandarización a índice mensual y depuración de duplicados por mes cuando existan), (iii) las transformaciones estadísticas requeridas para compatibilizar series de distinta frecuencia (en particular, la agregación del tipo de cambio originalmente diario a frecuencia mensual mediante promedio por mes calendario) y (iv) la construcción de variables derivadas para modelado (transformaciones de escala como logaritmo en la variable objetivo cuando aplique y rezagos de covariables para capturar la transmisión con retardos).

Aunque los archivos del BCH contienen un historial más amplio, el análisis se restringe explícitamente al horizonte común del estudio (2010-01 a 2025-08) definido para asegurar

disponibilidad simultánea de todas las variables, integrando las series en una sola base mensual por clave de mes calendario.

Finalmente, cualquier transformación temporal (rezagos y partición entrenamiento–prueba) se realiza respetando el orden cronológico, de forma que las variables explicativas utilizadas en cada periodo se construyen únicamente con información disponible hasta ese mes, evitando sesgo por información futura en la evaluación predictiva.

TABLA 10 Matriz de operacionalización de las variables

Variable	Definición conceptual	Definición operacional	Dimensión	Indicador/item
Crédito total al sector privado (Y)	Stock agregado de financiamiento otorgado por el sistema financiero al sector privado; refleja la profundidad y dinámica crediticia de la economía.	A partir de la data BCH (columna Valor) se construye la serie mensual Y_t . Para el modelado se emplea: (i) nivel nominal mensual; y (ii) transformación logarítmica $\ln(Y_t)$ cuando se requiera estabilizar varianza y linealizar elasticidades. De forma complementaria se pueden generar rezagos $Y_{t-1}, Y_{t-3}, Y_{t-6}, Y_{t-12}$ para capturar persistencia.	Actividad crediticia agregada	BCH EMF-AMCC-01 (Indicador 549)
Tasa de Política Monetaria (TPM) (X1)	Instrumento de política monetaria que fija el banco central y orienta las condiciones de liquidez y tasas del sistema.	Desde la data del BCH (columna Valor) se obtiene la serie mensual TPM_t en porcentaje. Para consistencia de modelado: (i) se mantiene en puntos porcentuales o se convierte a tasa decimal (única convención en todo el estudio); (ii) se construyen rezagos: $TPM_{t-1}, TPM_{t-3}, TPM_{t-6}, TPM_{t-12}$ para capturar retardos de transmisión; y (iii) opcionalmente se calcula el cambio mensual ΔTPM_t si el diagnóstico lo justifica.	Política monetaria	BCH EM-TPM-01 (Indicador 700).
Tasa activa promedio (X2)	Costo promedio del crédito en moneda nacional; aproxima condiciones de financiamiento para hogares y empresas.	Desde la data del BCH (columna Valor) se obtiene la tasa mensual $i_{activa,t}$. Para modelado: (i) se usa en nivel (pp o decimal según convención); (ii) se generan rezagos para reflejar transmisión gradual a demanda/oferta de crédito; y (iii) opcionalmente cambios $\Delta i_{activa,t}$ si se requiere estacionariedad.	Condiciones financieras del lado activo	BCH EMF-TI-01 (Indicador 580).

Variable	Definición conceptual	Definición operacional	Dimensión	Indicador/item
Tasa pasiva de ahorro (X3)	Remuneración promedio al ahorro; aproxima costo de fondeo y señales de preferencia por liquidez/ahorro.	Desde la data del BCH (columna Valor) se obtiene la tasa mensual i_{pasiva} , t. Para modelado: (i) se usa en nivel (pp o decimal según convención); (ii) se construyen rezagos; (iii) opcionalmente cambios $\Delta i_{pasiva,t}$ si el diagnóstico lo requiere. La serie está en frecuencia diaria. Se transforma a frecuencia mensual mediante el promedio mensual de los valores diarios disponibles (TC_mes). Para modelado: (i) se utiliza el promedio mensual TC_t; (ii) opcionalmente se usa $\ln(TC_t)$; y (iii) se construyen rezagos para capturar efectos retardados.	Condiciones financieras del lado pasivo	BCH EMF-TI-01 (Indicador 582)
Tipo de cambio nominal de venta (X4)	Precio del dólar en moneda local; refleja condiciones externas y expectativas que afectan costos financieros y decisiones de crédito.	Desde la data del BCH (columna Valor) se toma la inflación interanual mensual π_t (porcentaje). Para modelado: (i) se usa en nivel; (ii) se construyen rezagos; y (iii) si se requiere, se calcula el cambio $\Delta \pi_t$. Con el conjunto fuera de muestra se calcula el error $e_t = y_t - \hat{y}_t$ y se computan métricas: RMSE, MAE, MAPE y, cuando aplique por modelo, R^2 ajustado. Se reporta la mejora porcentual de cada modelo ML respecto al benchmark econométrico.	Condiciones cambiarias nominales	BCH EC-TCN-01 (Indicador 620)
Inflación interanual IPC (X5)	Variación anual del nivel de precios; aproxima presiones inflacionarias y condiciones reales que influyen sobre tasas reales y demanda de crédito.	Desde la data del BCH (columna Valor) se toma la inflación interanual mensual π_t (porcentaje). Para modelado: (i) se usa en nivel; (ii) se construyen rezagos; y (iii) si se requiere, se calcula el cambio $\Delta \pi_t$. Con el conjunto fuera de muestra se calcula el error $e_t = y_t - \hat{y}_t$ y se computan métricas: RMSE, MAE, MAPE y, cuando aplique por modelo, R^2 ajustado. Se reporta la mejora porcentual de cada modelo ML respecto al benchmark econométrico.	Dinámica de precios	BCH EP-IPC-01 (Indicador 609)
Desempeño predictivo (métricas)	Medidas cuantitativas de precisión para comparar modelos de pronóstico en condiciones homogéneas.	Desde la data del BCH (columna Valor) se toma la inflación interanual mensual π_t (porcentaje). Para modelado: (i) se usa en nivel; (ii) se construyen rezagos; y (iii) si se requiere, se calcula el cambio $\Delta \pi_t$. Con el conjunto fuera de muestra se calcula el error $e_t = y_t - \hat{y}_t$ y se computan métricas: RMSE, MAE, MAPE y, cuando aplique por modelo, R^2 ajustado. Se reporta la mejora porcentual de cada modelo ML respecto al benchmark econométrico.	Evaluación comparativa de pronósticos	RMSE; MAE; MAPE; R^2 ajustado (si aplica); mejora porcentual vs punto de referencia.

Fuente: Elaboración propia con base en datos del Banco Central de Honduras.

3.1.4 HIPÓTESIS

En coherencia con la pregunta y el objetivo generales del estudio, se formulan las siguientes hipótesis generales y específicas:

Hipótesis general:

- Hipótesis Nula General (H_{0g}): En el periodo 2010 al 2025, los modelos de machine learning basados en la TPM y otros determinantes macrofinancieros no presentan un desempeño de pronóstico fuera de muestra superior al de los modelos econométricos tradicionales de referencia (ARIMA, SARIMAX y VAR), medido mediante RMSE, MAE y MAPE (y medidas de ajuste complementarias cuando correspondan).
- Hipótesis Alternativa General (H_{1g}): En el período 2010 al 2025, al menos uno de los modelos de machine learning basados en la TPM y otros determinantes macrofinancieros sí presenta un desempeño de pronóstico fuera de muestra superior al de los modelos econométricos tradicionales de referencia (ARIMA, SARIMAX y VAR), reflejado en menores valores de RMSE, MAE y/o MAPE (y medidas de ajuste complementarias cuando correspondan).

Hipótesis Específicas:

Derivada de la comparación entre modelos univariantes (basados únicamente en la serie de crédito y su dinámica temporal) y modelos multivariantes (que incorporan TPM e indicadores macroeconómicos), se plantea:

Hipótesis específica 1: información incremental (univariante vs multivariante/exógenas):

- Hipótesis nula específica 1 $H_{0,1}$: La incorporación de la TPM y del conjunto de indicadores macrofinancieros seleccionados no mejora el pronóstico fuera de muestra del crédito respecto a un enfoque univariante basado en la dinámica histórica del propio crédito (benchmark tipo ARIMA), al comparar RMSE, MAE y MAPE bajo el mismo horizonte temporal de prueba.

- Hipótesis alternativa específica 1 $H_{1,1}$: La incorporación de la TPM y del conjunto de indicadores macrofinancieros seleccionados sí mejora el pronóstico fuera de muestra del crédito respecto al enfoque univariante (benchmark tipo ARIMA), evidenciado por menores RMSE, MAE y/o MAPE bajo el mismo horizonte temporal de prueba.

Hipótesis específica 2: superioridad predictiva (ML vs econometría tradicional):

- Hipótesis nula específica 2 $H_{0,2}$: Los modelos de machine learning no reducen el error de pronóstico fuera de muestra del crédito en comparación con los modelos econométricos multivariantes de referencia (SARIMAX y VAR, además de ARIMA), evaluados con RMSE, MAE y MAPE bajo el mismo esquema de validación temporal.
- Hipótesis alternativa específica 2 $H_{1,2}$: Al menos un modelo de machine learning sí reduce el error de pronóstico fuera de muestra del crédito en comparación con SARIMAX y VAR (además de ARIMA), reflejado en menores RMSE, MAE y/o MAPE bajo el mismo esquema de validación temporal.

Hipótesis específica 3: interpretabilidad y trazabilidad (XAI):

- Hipótesis nula específica 3 $H_{0,3}$: La aplicación de técnicas de interpretabilidad (SHAP/LIME) al modelo de machine learning con mejor desempeño predictivo no aporta claridad adicional sobre la contribución relativa de la TPM y demás determinantes macrofinancieros en la predicción del crédito, respecto a reportar únicamente el pronóstico del modelo.
- Hipótesis alternativa específica 3 $H_{1,3}$: La aplicación de técnicas de interpretabilidad (SHAP/LIME) al modelo de machine learning con mejor desempeño predictivo sí aporta claridad adicional al identificar y jerarquizar la contribución de la TPM y demás determinantes macrofinancieros en la predicción del crédito, fortaleciendo la trazabilidad del análisis y la discusión de implicaciones.

Estas hipótesis se sostienen en (i) la teoría del canal del crédito, que vincula la política monetaria y el volumen de préstamos mediante tasas y condiciones financieras (Mishkin, 2022), y

(ii) evidencia empírica que documenta mejoras predictivas al modelar crédito y variables financieras con enfoques multivariantes y, cuando corresponde, no lineales, especialmente cuando la comparación se realiza con evaluación fuera de muestra (Ozgun et al., 2021).

3.2 ENFOQUE Y MÉTODOS

La presente investigación adopta un enfoque cuantitativo, ya que utiliza series macrofinancieras mensuales oficiales del Banco Central de Honduras (BCH) para analizar y pronosticar el comportamiento del crédito bancario agregado al sector privado. La variable dependiente es el crédito al sector privado del sistema financiero hondureño, mientras que como variables explicativas principales se emplean la Tasa de Política Monetaria (TPM), la tasa activa en moneda nacional, la tasa pasiva de ahorro en moneda nacional, la inflación interanual y el tipo de cambio nominal de venta. En consecuencia, el problema se aborda mediante análisis estadístico, econometría de series de tiempo y modelos de machine learning supervisado.

En cuanto a su alcance, el estudio es correlacional-explicativo con orientación predictiva. Es correlacional porque examina la asociación entre el crédito y sus determinantes macrofinancieros; es explicativo porque contrasta si dichas variables aportan evidencia consistente con el mecanismo de transmisión monetaria hacia el crédito, en línea con la literatura del canal del crédito (Mishkin, 2022); y es predictivo porque compara formalmente la capacidad de distintos modelos para anticipar la trayectoria futura del crédito bancario fuera de muestra.

Desde el punto de vista metodológico, el estudio se apoya en un diseño no experimental y longitudinal de series de tiempo, ya que las variables no son manipuladas por el investigador, sino observadas tal como aparecen en las estadísticas oficiales del BCH a lo largo del período analizado. Bajo este diseño, se comparan dos familias de modelos: por un lado, modelos econométricos de referencia, especialmente ARIMA, SARIMAX y modelos multivariados de series de tiempo; y, por otro, modelos de machine learning orientados a regresión, incluyendo regresión lineal, Ridge, Lasso, Random Forest, Gradient Boosting, XGBoost y MLP. La comparación entre enfoques se realiza mediante métricas de error de pronóstico como RMSE, MAE, MAPE y R^2 ajustado, bajo partición cronológica y validación temporal, respetando el orden de la serie y evitando el uso de información futura, criterio fundamental en problemas de forecasting con series de tiempo. En este

marco, un modelo se considera preferible si mantiene un desempeño consistente en el tramo fuera de muestra, simulando condiciones reales de pronóstico.

3.3 DISEÑO DE LA INVESTIGACIÓN

El diseño de la presente investigación es no experimental, longitudinal y de series de tiempo con frecuencia mensual. Es no experimental porque las variables analizadas no son manipuladas por el investigador, sino observadas tal como aparecen en las estadísticas oficiales del Banco Central de Honduras (BCH). Es longitudinal porque emplea observaciones repetidas en el tiempo, lo que permite analizar persistencia, rezagos y cambios en la dinámica del crédito bancario agregado al sector privado.

Dado que el objetivo central del estudio es el pronóstico y la comparación de modelos, el diseño se estructura como un análisis de series de tiempo aplicado a datos macrofinancieros mensuales. En este marco, se consideran propiedades propias de este tipo de datos, como posible no estacionariedad, dependencia temporal, efectos rezagados y eventuales cambios de régimen. Por ello, la estimación incorpora pruebas de estacionariedad, transformaciones cuando son necesarias, especificaciones con rezagos y validación temporal estricta.

Bajo este diseño, se emplean como referencia modelos econométricos de series de tiempo, especialmente ARIMA y SARIMAX, junto con modelos de machine learning orientados a regresión. La comparación entre enfoques se realiza mediante partición cronológica y validación temporal, con el fin de simular condiciones reales de pronóstico y evitar sesgos por uso de información futura. En consecuencia, la evaluación del desempeño se basa en métricas de error fuera de muestra, criterio central para juzgar la utilidad predictiva de los modelos en este estudio.

3.3.1 POBLACIÓN

La población de interés corresponde al proceso estocástico generador de datos del crédito bancario agregado al sector privado en Honduras y de sus principales determinantes macrofinancieros. En términos empíricos, este proceso se observa a través de series mensuales oficiales del Banco Central de Honduras (BCH), particularmente las correspondientes al crédito total al sector privado, la Tasa de Política Monetaria (TPM), la tasa activa en moneda nacional, la tasa pasiva de ahorro en moneda nacional, la inflación interanual y el tipo de cambio nominal de

venta. En consecuencia, la investigación no trabaja con una población finita de individuos o casos, sino con la realización observable de un proceso temporal macrofinanciero. Esta conceptualización es consistente con la lógica de análisis en series de tiempo, donde el interés recae en la realización observable de un proceso temporal y no en una población finita de individuos o casos (Greene, 2012).

3.3.2 MUESTRA

El estudio utiliza un censo temporal correspondiente al período 2010-01 a 2025-08, integrado por 188 observaciones mensuales, una vez descargadas, depuradas y alineadas las series oficiales del BCH. El valor $N=188$ se justifica porque ese es el tramo común efectivo y comparable entre la variable dependiente y las variables explicativas seleccionadas, luego del proceso de integración, homologación de fechas y depuración de la base de datos. La unidad de análisis es cada mes, entendido como un vector de variables macrofinancieras observadas simultáneamente. Este tamaño muestral resulta adecuado para el propósito del estudio, ya que permite estimar y comparar modelos econométricos y de machine learning mediante partición cronológica y validación temporal, preservando la secuencia de la serie y evaluando el desempeño a través de pronóstico fuera de muestra, criterio coherente con la evaluación de modelos en series de tiempo (Chi et al., 2025; Greene, 2012).

3.3.3 TÉCNICAS DE MUESTREO

Dado que la investigación trabaja con series macrofinancieras mensuales oficiales del Banco Central de Honduras (BCH), no se emplea muestreo probabilístico en sentido clásico. En su lugar, se utiliza un censo temporal intencional, incorporando todas las observaciones mensuales disponibles y comparables dentro del recorte 2010-01 a 2025-08 para la variable objetivo y las variables explicativas seleccionadas. Este criterio es consistente con la práctica de modelado en series de tiempo, donde resulta necesario preservar la continuidad histórica y la dependencia temporal de las observaciones (Greene, 2012).

Dado que el objetivo del estudio es el pronóstico y la comparación de desempeño predictivo, la evaluación de los modelos se realiza mediante partición cronológica del conjunto de datos, separando un tramo inicial para entrenamiento y un tramo final para prueba. Este procedimiento es necesario porque, en series de tiempo, utilizar observaciones futuras durante el entrenamiento

introduce sesgo por anticipación y sobreestima el desempeño real del modelo. Por ello, la validación fuera de muestra constituye el criterio central para comparar de forma consistente modelos econométricos y de machine learning en problemas de forecasting (Chi et al., 2025).

El procedimiento aplicado consistió en: (i) delimitar el horizonte temporal común 2010-01 a 2025-08 de acuerdo con la disponibilidad y comparabilidad de las series del BCH; (ii) integrar en una base única las observaciones mensuales del crédito, la TPM, las tasas del sistema, la inflación y el tipo de cambio; (iii) mantener únicamente los meses con información válida y consistente para todas las variables del modelo; y (iv) reservar un bloque temporal final para evaluación fuera de muestra, preservando en todo momento el orden cronológico de la serie. En consecuencia, la técnica de muestreo utilizada se describe mejor como un censo temporal intencional con validación cronológica, adecuado para la naturaleza del problema analizado.

3.3.4 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Con el fin de garantizar la consistencia temporal, comparabilidad y calidad de datos para el modelado econométrico y predictivo, se definen criterios operativos, binarios y verificables para construir el conjunto final de análisis a partir del panel mensual integrado.

Notación:

- Sea $t \in 1, \dots, N$ el índice temporal mensual del horizonte 2010-01 a 2025-08, con $N = 188$.
- Sea y_t la variable dependiente (Crédito) y $x_{j,t}$ las variables explicativas (TPM, tasas, inflación, tipo de cambio).
- Sea $D = \{t: \text{mes dentro del horizonte}\}$ el conjunto de meses del índice mensual teórico.

Se incluye una serie $x_{j,t}$ y sus observaciones en el panel si cumple simultáneamente:

- Alineación temporal mensual: la serie puede representarse en frecuencia mensual y alinearse a D sin ambigüedad en fechas (mes calendario).

- Cobertura suficiente: Se incluye una serie únicamente si su nivel de completitud es adecuado dentro del horizonte 2010-01 a 2025-08. En términos operativos, se verifica el porcentaje de valores faltantes (meses sin dato) en toda la serie:
 - Criterio: la serie cumple si el porcentaje de valores faltantes es igual o menor al 5% del total de meses del horizonte.
 - Si excede 5%, la serie no se utiliza en la especificación del modelo.
- Dominio válido para transformaciones: Se incluye una serie solo si es compatible con las transformaciones necesarias para el análisis. En particular:
 - Si se aplica logaritmo al crédito (o a cualquier otra variable), se requiere que sus valores sean estrictamente positivos en todo el horizonte considerado.
 - Si la serie contiene valores cero o negativos en el tramo que se va a modelar y no existe un tratamiento metodológicamente justificable para corregirlo sin distorsión, esa serie (o ese tramo) se excluye para evitar resultados inválidos.

Se excluye una serie completa o un mes específico del conjunto final si se cumple al menos uno de los siguientes criterios:

- Faltantes excesivos en una serie: Se excluye la serie como predictor si el porcentaje de valores faltantes en el horizonte es mayor al 5%.
- Mes incompleto en variables requeridas: Para contribuir el conjunto final destinado a modelos multivariados, se excluye cualquier mes en el que falte información ya sea en la variable dependiente o cualquiera de las variables explicativas requeridas para el modelo.
- Inconsistencia o error evidente: Se excluye cualquier observación que presente valores claramente erróneos o incompatibles con la definición económica/contable de la variable (por ejemplo, magnitudes imposibles, signos incorrectos o valores fuera de rango esperable), cuando dicha inconsistencia no pueda corregirse validando contra la fuente oficial.
- No comparabilidad por cambios metodológicos: Se excluye el tramo afectado (o la serie) si la fuente reporta un cambio de base, definición o metodología que impida

comparar directamente los valores antes y después del cambio y no existe un procedimiento de empalme o ajuste documentado que preserve comparabilidad.

Cuando una variable está disponible en frecuencia diaria (por ejemplo, el tipo de cambio) y debe integrarse con variables mensuales, se transforma a frecuencia mensual mediante agregación por mes calendario. En el proceso de carga y limpieza se utilizó el promedio mensual:

- Para cada mes, se calcula el promedio de los valores diarios disponibles de ese mes.
- Si una variable ya está en frecuencia mensual, este paso no aplica y se conserva el valor tal como está reportado.

Debido a la naturaleza de las series macrofinancieras, se evalúa la estacionariedad mediante pruebas ADF y KPSS (según el plan de análisis). Si una serie no es estacionaria en niveles, el criterio operativo es transformarla antes de estimar modelos (mediante logaritmo, diferencias o tasas de variación), en lugar de excluirla automáticamente. La exclusión solo procede si la serie no puede transformarse de forma coherente con la definición del modelo o las transformaciones necesarias implican pérdida de comparabilidad o interpretación válida dentro del horizonte analizado.

3.4 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS

En este apartado se describen las técnicas, instrumentos y procedimientos empleados para construir la base de datos, preparar las series macrofinancieras y ejecutar el análisis empírico de la investigación. Dado que el estudio se desarrolla con series oficiales del Banco Central de Honduras (BCH) y bajo un diseño longitudinal de series de tiempo, el proceso empírico se implementa mediante un flujo programático reproducible en Python que permite extraer, integrar, transformar y analizar las observaciones mensuales del período 2010-01 a 2025-08. Sobre esta base se aplican técnicas de análisis exploratorio, econometría de series de tiempo y aprendizaje automático orientado a regresión. La comparación entre modelos se realiza bajo un esquema de validación fuera de muestra con partición cronológica, reportando métricas homogéneas de desempeño predictivo. En consecuencia, esta sección documenta el proceso técnico seguido desde la obtención

de los datos hasta la estimación, validación y contraste de modelos, con énfasis en la trazabilidad metodológica y la reproducibilidad del análisis.

3.4.1 TÉCNICAS

Las técnicas empleadas en esta investigación se organizan en cuatro bloques: obtención y preparación de datos, análisis exploratorio, modelado y evaluación predictiva. En primer lugar, la información se obtiene a partir de series oficiales del BCH mediante extracción programática y posterior integración en una base mensual unificada. Las variables incluidas son el crédito total al sector privado, la Tasa de Política Monetaria (TPM), la tasa activa en moneda nacional, la tasa pasiva de ahorro en moneda nacional, la inflación interanual y el tipo de cambio nominal de venta. Esta etapa permite asegurar trazabilidad de la fuente, comparabilidad entre variables y consistencia temporal del panel utilizado en el estudio.

En segundo lugar, se aplican técnicas de preparación de datos orientadas a la construcción de una base analítica válida para modelado. Estas técnicas incluyen estandarización de fechas, alineación temporal de las series, armonización de frecuencia cuando fue necesario, integración en una sola matriz de datos, verificación de continuidad del horizonte de estudio y control de calidad mediante revisión de duplicados, valores faltantes, escalas y observaciones atípicas. En particular, para variables originalmente publicadas con frecuencia distinta de la mensual, se realizó la agregación correspondiente antes de su incorporación al panel, con el fin de garantizar comparabilidad entre series observadas en una misma unidad temporal.

En tercer lugar, se emplean técnicas de análisis exploratorio de datos, con el objetivo de describir el comportamiento estadístico y temporal de las series antes del modelado. Estas técnicas comprenden visualización temporal, estadística descriptiva, análisis de asociaciones entre variables, identificación de valores extremos y revisión de patrones que pudieran afectar la estabilidad de los modelos. Asimismo, se aplican transformaciones y construcciones derivadas propias del análisis de series de tiempo, tales como logaritmos, diferencias, tasas de variación, rezagos de la variable dependiente y de variables explicativas, y estandarización cuando el algoritmo lo requiere. Estas transformaciones permiten representar con mayor adecuación la dinámica temporal del crédito y de sus determinantes macrofinancieros (Greene, 2012).

En cuarto lugar, se aplican técnicas de modelado predictivo. En el bloque econométrico se estiman modelos ARIMA y SARIMAX, utilizados como referencia para representar la dependencia temporal del crédito e incorporar, cuando corresponde, el aporte de variables exógenas. En el bloque de aprendizaje automático se entrenan modelos supervisados orientados a regresión, incluyendo regresión lineal, Ridge, Lasso, Random Forest, Gradient Boosting, XGBoost y MLP, con el propósito de contrastar si enfoques más flexibles mejoran el pronóstico fuera de muestra. La elección de estas técnicas responde a su uso frecuente en problemas de pronóstico macrofinanciero y financiero, así como a la necesidad de comparar especificaciones lineales, regularizadas y no lineales en un mismo entorno empírico (Li et al., 2022; Stempień & Ślepaczuk, 2025).

Finalmente, la evaluación de todas las técnicas se realiza mediante partición cronológica y validación temporal, preservando el orden secuencial de la serie para evitar sesgos por uso de información futura. Bajo este esquema, los modelos se comparan con base en métricas homogéneas de error de pronóstico, particularmente RMSE, MAE y MAPE, complementadas con R^2 ajustado cuando corresponde. Este criterio resulta central en ejercicios de forecasting con series de tiempo, ya que permite valorar la utilidad real de los modelos en condiciones equivalentes de predicción fuera de muestra (Chi et al., 2025; Stempień & Ślepaczuk, 2025).

La selección de RMSE, MAE y MAPE como métricas centrales de evaluación en lugar de criterios de información dentro de la muestra como AIC o BIC, responde a tres consideraciones técnicas:

- AIC y BIC son criterios de bondad de ajuste dentro de la muestra, que penalizan el número de parámetros para favorecer parsimonia en modelos paramétricos anidados; en cambio, esta investigación evalúa capacidad predictiva fuera de muestra, que es la pregunta operativamente relevante para un sistema de pronóstico institucional. AIC mide qué tan bien un modelo describe los datos pasados; RMSE walk-forward mide qué tan bien anticipa los datos futuros.
- AIC requiere log-verosimilitud paramétrica comparable, que está disponible para ARIMA y SARIMAX, pero no se define de forma equivalente para los modelos de machine learning evaluados (Lasso, Random Forest, XGBoost, MLP); aplicar AIC

entre paradigmas heterogéneos rompería la simetría metodológica que es justamente el principio rector del diseño comparativo.

- En muestras macroeconómicas relativamente pequeñas ($N = 188$ observaciones) y con quiebres estructurales como el choque COVID-19 documentado en §4.3.1, los criterios in-sample tienden a favorecer especificaciones sobreparametrizadas que se desempeñan deficientemente fuera de muestra (Hyndman & Athanasopoulos, 2018). Por estas razones, la evaluación se fundamenta en métricas de error fuera de muestra bajo validación walk-forward, complementadas con la prueba de Diebold-Mariano para contraste estadístico de igualdad predictiva, criterio estándar en la literatura contemporánea de pronóstico macroeconómico (Diebold & Mariano, 1995; Stock & Watson, 2012).

3.4.2 INSTRUMENTOS

En esta investigación, los instrumentos no corresponden a cuestionarios ni escalas aplicadas a sujetos, sino a instrumentos técnicos de medición y análisis apropiados para un estudio cuantitativo de series de tiempo macrofinancieras. En términos operativos, el instrumento principal es un pipeline programático reproducible, implementado en Python, que permite capturar, integrar, transformar, modelar y evaluar las series oficiales del Banco Central de Honduras (BCH) de forma trazable y replicable. Este pipeline opera sobre una base de datos mensual integrada, en la cual cada fila representa un mes del período 2010-01 a 2025-08 y cada columna corresponde a una variable macrofinanciera del estudio, particularmente crédito al sector privado, Tasa de Política Monetaria, tasa activa en moneda nacional, tasa pasiva de ahorro en moneda nacional, inflación interanual y tipo de cambio nominal de venta. Su función instrumental consiste en asegurar que la información utilizada conserve consistencia temporal, comparabilidad entre variables y correspondencia directa con su fuente oficial.

Como instrumento complementario, la investigación utiliza un diccionario de datos y metadatos que documenta para cada variable su nombre operativo, descripción, unidad de medida, frecuencia, período de cobertura, fuente exacta dentro del BCH y transformaciones aplicadas. Este componente permite auditar la construcción de la base y reducir ambigüedades en la interpretación de las series empleadas. Asimismo, forman parte del instrumental los modelos matemáticos

parametrizados utilizados en el estudio, tanto econométricos como de machine learning. En el bloque econométrico, los instrumentos analíticos corresponden a especificaciones ARIMA y SARIMAX, definidas por parámetros de dependencia temporal, diferenciación y regresores exógenos; en el bloque de machine learning, corresponden a modelos supervisados de regresión parametrizados mediante coeficientes, penalizaciones o estructuras de árboles y redes. Finalmente, se utilizan rutinas estandarizadas de evaluación para generar tablas de métricas, gráficos de valores observados versus predichos y resúmenes comparativos bajo una misma arquitectura temporal. En conjunto, estos instrumentos permiten que la medición, el análisis y la comparación de modelos se realicen de forma homogénea, transparente y reproducible.

3.4.3 PROCEDIMIENTOS APLICADOS

Con el objetivo de asegurar rigurosidad y replicabilidad, los procedimientos del estudio se organizan como una secuencia reproducible de etapas que integran extracción de datos secundarios oficiales, control de calidad, preparación de series, estimación de modelos y evaluación comparativa. La secuencia es congruente con enfoques de proyectos analíticos basados en fases y con las prácticas de pronóstico en series de tiempo, donde la validación fuera de muestra es un criterio central (Octavio & Lopéz, 2024; Stempień & Ślepaczuk, 2025).

El procedimiento aplicado se ejecuta en las siguientes etapas:

- Se define el horizonte de análisis 2010-01 a 2025-08 con base en la disponibilidad continua de la variable objetivo (crédito total al sector privado). En esta etapa se fijan las variables a utilizar y su rol en el modelo (dependiente y explicativas), conforme a la matriz de operacionalización y a la disponibilidad de series oficiales del BCH (Banco Central de Honduras, 2024b).
- Se descargan las series oficiales mediante la API del BCH: crédito al sector privado (EMF-AMCC-01_549), TPM (EM-TPM-01_700), tasa activa MN (EMF-TI-01_580), tasa pasiva MN (EMF-TI-01_582), inflación interanual (EP-IPC-01_609) y tipo de cambio nominal de venta (EC-TCN-01_620). Posteriormente, se consolidan los archivos en un entorno de trabajo reproducible. La selección de variables se vincula con su uso institucional en reportes de seguimiento macrofinanciero (Banco Central de Honduras, 2024b).

- Se construye una base mensual unificada donde cada fila corresponde a un mes del periodo y cada columna a una variable. En esta etapa se ejecutan procedimientos de ETL: estandarización de fechas, alineación por mes calendario, unión de series y verificación de unicidad por mes. Cuando una variable está disponible en una frecuencia distinta, se transforma a frecuencia mensual mediante un criterio de agregación consistente, previo a integrarla con el resto del panel.
- Con la base integrada se realizan verificaciones de consistencia temporal (continuidad del índice mensual, ausencia de duplicados), revisión de valores faltantes y detección de posibles atípicos. Asimismo, se aplican los criterios de inclusión/exclusión definidos para asegurar comparabilidad y consistencia del conjunto final de análisis. Cuando corresponde, se contrasta la coherencia general de las series con estadísticas institucionales reportadas por el BCH (Banco Central de Honduras, 2024b).
- Se aplican transformaciones consistentes con el tratamiento de series macrofinancieras y con los requerimientos del modelado: logaritmos en variables de nivel cuando corresponde, diferencias o tasas de variación para capturar cambios, y construcción de rezagos de la variable dependiente y/o regresores relevantes. La incorporación de rezagos responde a la lógica de dinámica temporal y transmisión con retardos en variables macrofinancieras (Greene, 2012).
- Una vez consolidada la base, se aplica una partición temporal: un tramo inicial para entrenamiento/estimación y un tramo final reservado para evaluación fuera de muestra. La partición respeta el orden cronológico para evitar sesgo por información futura y simular condiciones reales de pronóstico, criterio estándar en evaluación de modelos de series de tiempo (Chi et al., 2025; Stempień & Ślepaczuk, 2025).
- Se especifica y estima un modelo econométrico de referencia (ARIMA/SARIMAX) utilizando el tramo de entrenamiento, incorporando la dinámica temporal y, cuando corresponde, variables exógenas. Este modelo funciona como punto de comparación para contrastar si los algoritmos de aprendizaje automático aportan mejoras relevantes en pronóstico, en línea con la práctica econométrica aplicada (Greene, 2012).

- Se entrenan modelos supervisados de regresión (regresión regularizada, árboles y ensambles como Random Forest y boosting) sobre el mismo tramo de entrenamiento. En esta etapa se ajustan hiperparámetros y se controla complejidad para favorecer generalización. La selección de modelos se fundamenta en evidencia reciente de uso de técnicas de aprendizaje automático para pronóstico macrofinanciero y/o variables relacionadas con crédito (Ozgur et al., 2021; Stempień & Ślepaczuk, 2025).
- Con los modelos estimados, se generan pronósticos sobre el tramo de prueba fuera de muestra y se calculan métricas de desempeño (RMSE, MAE, MAPE) de forma homogénea. La comparación entre el modelo econométrico y los modelos de aprendizaje automático permite evaluar si existe mejora en precisión predictiva bajo un criterio válido de pronóstico (Chi et al., 2025). Los resultados se documentan mediante tablas y gráficos estandarizados para asegurar trazabilidad y replicabilidad.

3.5 FUENTES DE INFORMACIÓN

En esta investigación se utilizan exclusivamente fuentes secundarias, de forma articulada, con el fin de garantizar evidencia empírica sólida y un sustento conceptual y metodológico robusto.

Siguiendo la literatura metodológica, las fuentes primarias se entienden como información recopilada de primera mano por el investigador mediante medición directa, encuestas, entrevistas, experimentos u otros instrumentos aplicados específicamente para el estudio. Por su parte, las fuentes secundarias corresponden a información producida por terceros y posteriormente sistematizada, publicada o puesta a disposición para su uso, incluyendo estadísticas oficiales, reportes institucionales, artículos científicos, libros y documentos normativos (Hernández Sampieri et al., 2006).

En este estudio, no se generaron datos primarios mediante instrumentos propios. En consecuencia, la evidencia cuantitativa utilizada proviene de fuentes secundarias de origen oficial, principalmente series estadísticas publicadas por el Banco Central de Honduras (BCH) y la Comisión Nacional de Bancos y Seguros (CNBS), que recogen el comportamiento del crédito al sector privado, las tasas de interés, la inflación, el tipo de cambio y variables de política monetaria. Dichas series se emplean como insumo para estimar y validar los modelos econométricos y de

machine learning. Estas estadísticas se publican y validan regularmente en documentos como la Memoria Anual 2024 y el Informe de Estabilidad Financiera 2024, donde se reportan saldos, tasas e indicadores del sistema financiero y se explicita que la información proviene de los departamentos técnicos del BCH y de la CNBS (Banco Central de Honduras, 2024a).

Las fuentes secundarias incluyen textos de metodología, teoría económica, econometría y machine learning, así como estudios empíricos recientes sobre pronóstico macroeconómico y crédito bancario. Entre ellas destacan la obra de Hernández Sampieri et al. (2006) para la fundamentación del enfoque cuantitativo; los desarrollos de Mishkin sobre transmisión de la política monetaria y el canal del crédito bancario; los manuales de econometría de Greene, que sustentan el uso de modelos de series de tiempo y regresiones dinámicas; y una serie de artículos que comparan modelos tradicionales (ARIMA, VAR, regresión lineal) con algoritmos de machine learning en la predicción de variables macroeconómicas y financieras (Araujo & Gaglianone, 2023; Baya et al., 2025; Coulombe et al., 2020).

En conjunto, estas fuentes permiten diferenciar claramente entre la evidencia directa (las series que se modelan) y la evidencia contextual, teórica y comparativa (los estudios y marcos conceptuales que se usan para interpretar los resultados y para justificar las decisiones metodológicas), cumpliendo con el criterio de triangulación entre datos, teoría y métodos que recomienda la literatura de investigación cuantitativa (Hernández Sampieri et al., 2006).

3.5.1 FUENTES SECUNDARIAS (ORIGEN OFICIAL)

Las fuentes de información cuantitativa de esta tesis están constituidas por series estadísticas oficiales publicadas por el Banco Central de Honduras (BCH) y, cuando corresponde, por la Comisión Nacional de Bancos y Seguros (CNBS). Estas series se obtienen mediante el consumo de la API y repositorios institucionales, y se utilizan como insumo para la estimación, validación y comparación de los modelos de pronóstico. En términos metodológicos, se clasifican como fuentes secundarias de origen oficial, dado que fueron generadas por instituciones públicas competentes y posteriormente descargadas y procesadas por los autores para fines analíticos (Hernández Sampieri et al., 2006).

En particular, se emplean las siguientes series mensuales:

- Crédito total del sistema financiero al sector privado (indicador 549, grupo EMF-AMCC-01), que constituye la variable dependiente principal del estudio. Esta serie recoge el saldo de crédito otorgado al sector privado residente por las entidades supervisadas y es utilizada por el propio BCH en la caracterización del ciclo crediticio y de la estabilidad financiera, tal como se documenta en el Informe de Estabilidad Financiera 2024 (Banco Central de Honduras, 2024a).
- Tasa de Política Monetaria (TPM) mensual (EM-TPM-01_700), que resume la postura de la política monetaria del BCH y se emplea como variable explicativa central, en línea con la literatura sobre el canal del crédito bancario y la transmisión de la política monetaria.
- Tasa de interés activa promedio en moneda nacional (EMF-TI-01_580) y tasa de interés pasiva de ahorro en moneda nacional (EMF-TI-01_582), que reflejan las condiciones de costo del crédito y de remuneración del ahorro para el sector privado. En el Informe de Estabilidad Financiera se presentan estas tasas como indicadores clave de las condiciones financieras y del comportamiento de la banca (Banco Central de Honduras, 2024a).
- Inflación interanual del Índice de Precios al Consumidor (IPC) (EP-IPC-01_609), que captura el entorno inflacionario relevante para la toma de decisiones del banco central y para la demanda de crédito. La Memoria Anual 2024 del BCH utiliza esta serie como una de las variables centrales en el diagnóstico macroeconómico (Banco Central de Honduras, 2024b).
- Tipo de cambio nominal de venta (EC-TCN-01_620), originalmente disponible a frecuencia diaria y agregado a frecuencia mensual (mediante promedios o cierres mensuales) para su integración con el resto de las variables. El IEF documenta que el tipo de cambio es un componente clave de las condiciones financieras externas y de la estructura de fondeo de la banca (Banco Central de Honduras, 2024a).

Todas estas series cubren el período 2010-01 a 2025-08 (una vez homologadas y depuradas) y corresponden a registros oficiales generados por las áreas técnicas del BCH y, en algunos casos, por la CNBS. Se incorporan como fuentes documentales oficiales (secundarias de origen oficial) las normas prudenciales emitidas por la CNBS (en particular, la Circular C-003-

2022: Norma para la Evaluación y Clasificación de la Cartera Crediticia), en tanto definen operativamente la clasificación de préstamos, el cálculo de reservas y los criterios de riesgo que condicionan la oferta de crédito y que, por ende, enmarcan el comportamiento de la variable dependiente. En conjunto, estas fuentes secundarias oficiales proporcionan la evidencia cuantitativa directa sobre la que se estiman los modelos econométricos y de machine learning y se evalúa su capacidad de pronóstico del crédito bancario hondureño (Banco Central de Honduras, 2024a, 2024b; Comisión Nacional de Bancos y Seguros, 2022, 2024).

3.5.2 FUENTES SECUNDARIAS BIBLIOGRÁFICAS Y TÉCNICAS

Las fuentes secundarias empleadas en esta tesis complementan y contextualizan la evidencia primaria, proporcionando el sustento teórico, metodológico y comparativo necesario para interpretar los resultados y justificar las decisiones de diseño de la investigación.

En el plano metodológico, se toma como referencia principal la obra de Hernández Sampieri, Fernández Collado y Baptista (2006), que desarrolla de manera sistemática el enfoque cuantitativo, la formulación de problemas e hipótesis, la definición de variables y la operacionalización, así como la clasificación de fuentes de información en primarias y secundarias. Este texto sirve de base para la estructura del capítulo metodológico y para la justificación del uso de datos secundarios oficiales como insumo principal del estudio.

En el plano teórico-económico, se recurre a Mishkin y a la literatura de banca y mercados financieros para conceptualizar el rol del crédito al sector privado en la transmisión de la política monetaria, el funcionamiento del canal del crédito bancario y la interacción entre tasas de interés, inflación y actividad económica. Estos aportes permiten interpretar la relación entre la TPM, las tasas activas y pasivas, el tipo de cambio y el comportamiento del crédito, así como formular hipótesis coherentes con la teoría del canal bancario de transmisión monetaria.

En cuanto al marco econométrico, se utilizan manuales como Greene, W. H. - *Econometric Analysis*, que presentan los fundamentos de los modelos de regresión, series de tiempo, modelos dinámicos y técnicas de estimación y validación, y que justifican el uso de estructuras con rezagos y de pruebas de bondad de ajuste y diagnóstico en el contexto de modelos de pronóstico.

En el plano empírico y de machine learning, se consideran varios trabajos que comparan modelos tradicionales con algoritmos de aprendizaje automático en la predicción de variables macroeconómicas y financieras. Por ejemplo:

- (Coulombe et al., 2020), quienes analizan la utilidad del machine learning para el pronóstico macroeconómico y muestran que modelos como Random Forest, boosting o redes neuronales pueden mejorar a modelos lineales en ciertos contextos.
- (Araujo & Gaglianone, 2023), que evalúan métodos de machine learning para el pronóstico de la inflación en Brasil y los comparan con modelos clásicos, resaltando las condiciones bajo las cuales los algoritmos no lineales aportan ganancias de precisión.
- (Baya et al., 2025), quienes comparan ARIMA, Random Forest y un modelo de factor dinámico en el pronóstico del tipo de cambio real efectivo, ilustrando la pertinencia de enfoques híbridos y comparativos en series financieras.
- Estudios aplicados al monitoreo del crédito y a la construcción de indicadores de creación de crédito en economías emergentes, como (C. Giraldo et al., 2024) que informan el diseño de indicadores y la interpretación de la dinámica crediticia.

De la misma manera, se incorporan fuentes secundarias de organismos internacionales y reguladores (tales como el Global Findex 2021 del Banco Mundial (Demirgüç-Kunt et al., 2022), estudios del FMI sobre heterogeneidad en la transmisión de la política monetaria (Deb, 2023) y documentos del propio BCH como el Informe de Estabilidad Financiera 2024 y la Memoria Anual 2024) que aportan evidencia comparativa y regional sobre la evolución del crédito, la inclusión financiera y los canales de transmisión.

3.6 PLAN DE ANÁLISIS

En congruencia con el enfoque cuantitativo y el diseño no experimental longitudinal de esta investigación, el análisis de datos se organizará en un plan secuencial que integra análisis descriptivo, modelado econométrico y modelado predictivo con técnicas de machine learning, así como una evaluación comparativa rigurosa de la capacidad de pronóstico del crédito bancario hondureño. En términos metodológicos, el plan de análisis especifica de antemano qué transformaciones, estadísticas descriptivas, modelos e indicadores se utilizarán para responder a

las preguntas de investigación y contrastar las hipótesis planteadas, siguiendo la recomendación de que los estudios cuantitativos definan explícitamente sus procedimientos de procesamiento, análisis descriptivo e inferencial antes de aplicar las técnicas estadísticas sobre la base de datos definitiva (Hernández Sampieri et al., 2006).

El conjunto de datos está constituido por 188 observaciones mensuales correspondientes al período 2010-01 a 2025-08, organizadas en una matriz donde cada fila representa un mes y cada columna una variable: crédito total del sistema financiero al sector privado (variable dependiente) y, como variables explicativas, la tasa de política monetaria, las tasas de interés activa y pasiva en moneda nacional, la inflación interanual del IPC y el tipo de cambio nominal de venta. Esta estructura matricial es la forma estándar de organización de datos para la estimación de modelos de regresión y series de tiempo en econometría aplicada (Greene, 2012).

El plan de análisis se desarrollará en cinco fases principales:

Fase 1: Preparación y análisis descriptivo de las series:

1. Verificación y limpieza de la base de datos:

- a. Comprobación de la consistencia temporal (ausencia de huecos en el intervalo 2010-01 / 2025-08) y detección de valores faltantes o atípicos mediante inspección gráfica y estadísticos básicos.
- b. Tratamiento de valores faltantes cuando corresponda (imputación simple coherente con la naturaleza temporal de las series) y revisión de posibles quiebres de serie asociados a cambios metodológicos señalados en las notas técnicas del Banco Central de Honduras (BCH) y en sus publicaciones periódicas.

2. Análisis exploratorio de datos (EDA):

- a. Cálculo de medidas de tendencia central, dispersión y forma (media, mediana, desviación estándar, coeficientes de variación) para cada variable, así como matrices de correlación entre el crédito y sus posibles determinantes.
- b. Elaboración de gráficos de líneas de las series en niveles y de sus tasas de variación, con el fin de identificar tendencias, cambios de régimen y episodios de estrés macrofinanciero.

- c. Este tipo de análisis descriptivo constituye el primer paso recomendado en el tratamiento de datos cuantitativos, antes de proceder a la modelación inferencial o predictiva (Hernández Sampieri et al., 2006).
3. Transformaciones y pruebas preliminares de propiedades de las series:
 - a. Aplicación de transformaciones (logaritmos del crédito y otras variables en nivel, diferencias o tasas de crecimiento) para mejorar la estabilidad de varianza y favorecer interpretaciones en términos de cambios porcentuales, siguiendo la práctica usual en econometría de series de tiempo y en aplicaciones de machine learning financiero.
 - b. Realización de pruebas de estacionariedad y análisis de posibles estructuras de rezagos, como insumo para la especificación de los modelos econométricos de referencia y de los conjuntos de variables de entrada para los algoritmos de machine learning (Greene, 2012).

Fase 2: Estimación del modelo econométrico de referencia:

1. Especificación y estimación del modelo lineal base:
 - a. Construcción de uno o más modelos econométricos de referencia (modelos de regresión dinámica o ARIMA/ARIMAX) donde el crédito al sector privado se explique por sus propios rezagos y por la tasa de política monetaria, las tasas de interés, la inflación y el tipo de cambio.
 - b. La elección de un modelo econométrico lineal como modelo de referencia es consistente con la práctica de la literatura de pronóstico financiero, en la que los modelos ARIMA y modelos de regresión con rezagos se utilizan como punto de comparación para métodos más avanzados (Greene, 2012).
2. Diagnóstico del modelo de referencia:
 - a. Para asegurar la rigurosidad del modelo estadístico que servirá como benchmark, se procede a una evaluación diagnóstica exhaustiva. Dicha evaluación incluye la verificación de los supuestos econométricos fundamentales (residuos, autocorrelación y estabilidad de parámetros), así como la cuantificación de su ajuste descriptivo dentro de la muestra.

- b. Solo tras confirmar la coherencia y validez de esta línea base, resulta metodológicamente apropiado contrastar su desempeño predictivo con el de los algoritmos de machine learning más flexibles (Stempień & Ślepaczuk, 2025).

Fase 3: Entrenamiento de modelos de machine learning:

1. Definición de conjuntos de entrenamiento y prueba:

- a. Partición cronológica de la base de datos en un tramo de entrenamiento (aprox. 70–80 % de las observaciones iniciales) y un tramo de prueba fuera de muestra (20–30 % final), respetando el orden temporal y evitando cualquier muestreo aleatorio que rompa la dependencia secuencial.
- b. La literatura en pronóstico macroeconómico y financiero enfatiza la necesidad de reservar un tramo de datos fuera de muestra que no se utilice ni para la estimación ni para la selección de modelos, como criterio de evaluación honesta del desempeño predictivo (Chi et al., 2025).

2. Entrenamiento de algoritmos supervisados:

- a. Modelos de Regresión y modelos de ensamble (Random Forest y gradient boosting) ampliamente utilizados en problemas de predicción financiera y de riesgo de crédito.

3.6 Plan de Análisis (Flujo de análisis de datos y modelado)

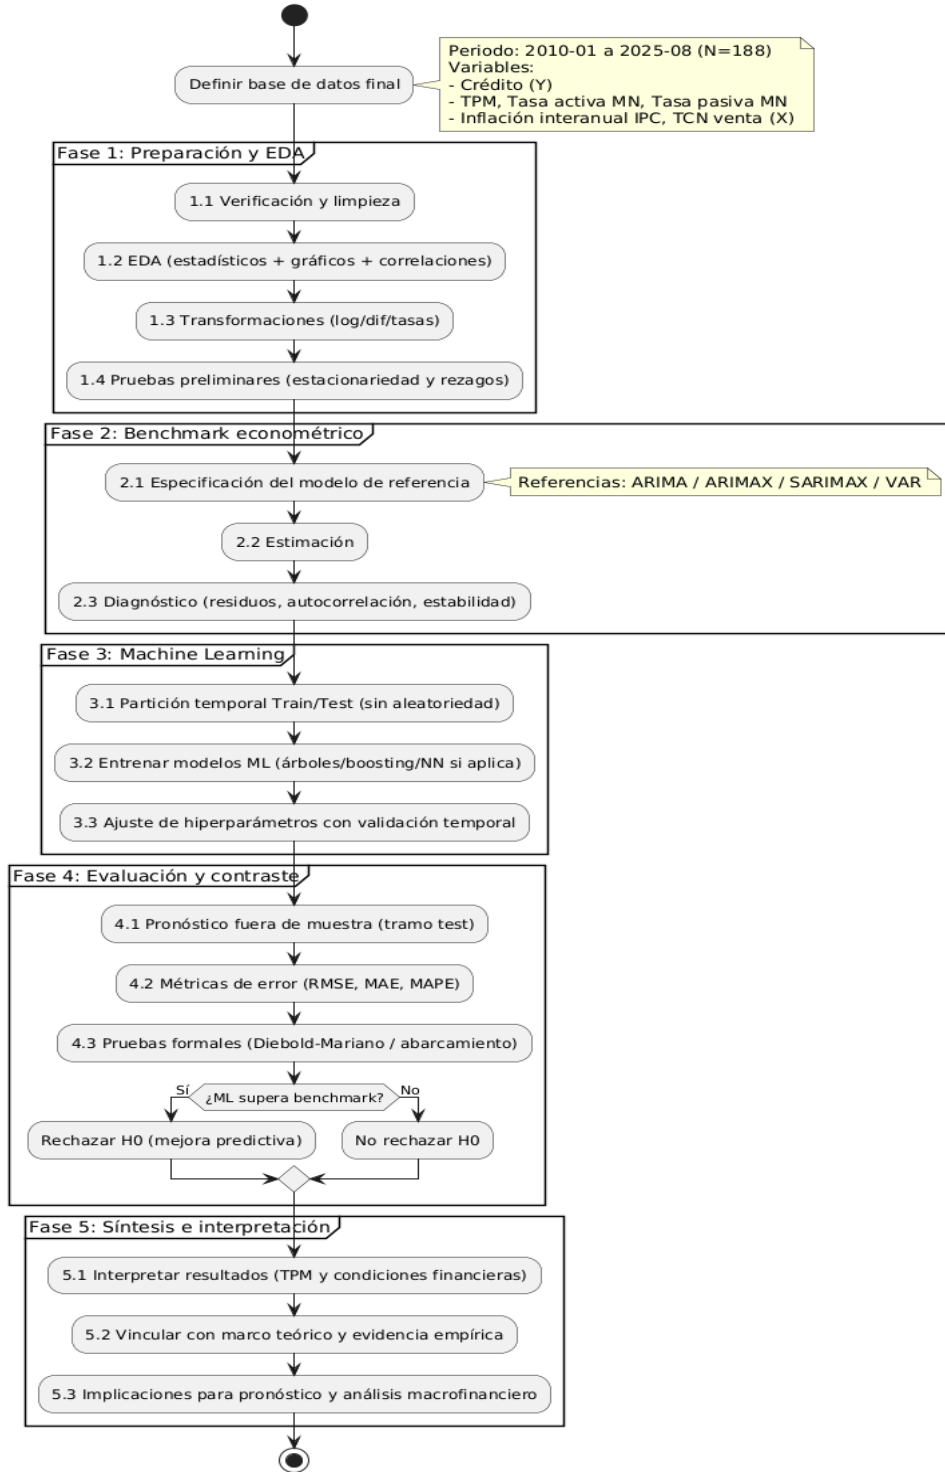


Ilustración 3 Diagrama de flujo del plan de análisis de datos (fases 1–5)

Fuente: Elaboración propia en base al plan de análisis.

TABLA 11 Red PERT del plan de análisis (pipeline cuantitativo)

Código	Actividad	Descripción breve	Predecesoras	Entregable verificable
A	Verificación y limpieza	Consistencia temporal, faltantes, duplicados, outliers documentados	—	Base validada (rango 2010-01/2025-08; N=188) Tablas/figuras EDA
B	EDA	Descriptivos, correlaciones, gráficos de series	A	(descriptivos, heatmaps, líneas) Variables transformadas + tabla de estacionariedad
C	Transformaciones y pruebas preliminares	log(crédito), crecimientos, diferencias; ADF/KPSS; análisis rezagos	B	Modelo econométrico estimado + predicciones base
D	Benchmark econométrico	Especificación y estimación ARIMA/ARIMAX/SARIMAX/VAR	C	Matriz X/y + partición train/test reproducible
E	Preparación ML	Features con rezagos, estandarización, split temporal	C	Diagnóstico del benchmark + decisión de validez
F	Diagnóstico benchmark	Residuos, autocorrelación, estabilidad (validación del benchmark)	D	Modelos ML entrenados + mejores parámetros
G	Entrenamiento ML	Entrenar modelos supervisados + ajuste hiperparámetros con validación temporal	E	Serie predicha benchmark en tramo test
H	Pronóstico fuera de muestra (benchmark)	Forecast en tramo test con el modelo econométrico validado	F	Tabla comparativa final + pruebas estadísticas
I	Evaluación comparativa	RMSE/MAE/MAPE/R2; Diebold-Mariano; análisis final	G, H	

Fuente: elaboración propia en base al plan de análisis.

El uso de estos algoritmos está respaldado por evidencia que demuestra su capacidad para superar a los modelos paramétricos tradicionales, especialmente en entornos de relaciones no lineales y alta complejidad en los datos. Este hallazgo es consistente tanto con la tesis de López Olea, que desarrolló un modelo de machine learning para la estimación de ingresos en el contexto de crédito de consumo, como con estudios recientes en el pronóstico de activos financieros (Octavio & Lopéz, 2024).

3. Ajuste de hiperparámetros y validación interna:
 - a. Para cada modelo de machine learning se llevará a cabo un ajuste de hiperparámetros mediante esquemas de validación apropiados para series de tiempo (validación con ventanas temporales), asegurando que la selección de hiperparámetros no “vea” el tramo de prueba.
 - b. En el pronóstico financiero con modelos híbridos y de machine learning son importantes los esquemas de validación para evitar sobreajuste y también obtener medidas realistas del desempeño del modelo fuera de la muestra.

Fase 4. Evaluación de la capacidad de pronóstico y contraste de hipótesis:

1. Generación de pronósticos fuera de muestra:
 - a. Utilizando únicamente la información disponible hasta cada punto del tramo de prueba, se generarán pronósticos del crédito con el modelo econométrico de referencia y con cada uno de los modelos de machine learning.
 - b. Para cada mes del tramo de prueba se obtendrá el valor pronosticado de la variable dependiente y el error de pronóstico (diferencia entre el valor observado y el pronosticado).

Este enfoque reproduce el esquema habitual de evaluación de pronósticos en macroeconomía y finanzas, donde la comparación entre modelos se realiza sobre trayectorias efectivamente no utilizadas en la estimación ni en el ajuste de los parámetros, tal como se discute en los manuales de pronóstico macroeconómico y en la literatura sobre evaluación de modelos para series de tiempo (Stock & Watson, 2012).

2. Cálculo de métricas de error y comparación de desempeño:
 - a. Se calcularán indicadores estándar de precisión de pronóstico, tales como el error cuadrático medio (RMSE) y el error absoluto medio (MAE).
 - b. En la literatura aplicada al pronóstico de series financieras y a modelos de riesgo de crédito basados en machine learning, el RMSE y el MAE se emplean de forma sistemática para comparar la capacidad predictiva relativa de modelos econométricos y de machine learning sobre datos fuera de muestra, tanto en ejercicios de pronóstico macroeconómico como en estudios de scoring y

estimación de variables financieras (Octavio & López, 2024; Stock & Watson, 2012).

De manera específica, la hipótesis general de la investigación (los modelos de machine learning basados en la TPM y otros determinantes macrofinancieros mejoran la capacidad de pronóstico del crédito frente a un modelo econométrico de referencia) se contrastará comparando estas métricas entre el modelo lineal y cada modelo de machine learning sobre el tramo de prueba, siguiendo la lógica de los ejercicios de comparación de pronósticos que contrastan modelos tradicionales con algoritmos más flexibles (Stock & Watson, 2012).

11. Pruebas formales de comparación de modelos:

Además de las métricas de error, se considerará la aplicación de pruebas formales de comparación de pronósticos, como la prueba de Diebold–Mariano y pruebas de abarcamiento de pronósticos, que permiten evaluar si las diferencias en precisión entre dos modelos son estadísticamente significativas sobre un mismo conjunto de datos fuera de muestra. Estos procedimientos forman parte del conjunto de herramientas estándar para la evaluación de modelos de pronóstico en macroeconomía y finanzas, y complementan el análisis basado únicamente en indicadores como el RMSE y el MAE (Stock & Watson, 2012). Con base en estos resultados se contrastará la hipótesis nula de que los modelos de machine learning no mejoran significativamente la capacidad de pronóstico respecto del modelo econométrico, frente a la hipótesis alternativa de que al menos uno de ellos presenta una precisión predictiva superior en el crédito al sector privado hondureño.

Fase 5. Síntesis, interpretación y vinculación con el marco teórico:

1. Interpretación de resultados y articulación con la teoría y la evidencia empírica:
 - a. Cómo la tasa de política monetaria y las condiciones financieras (tasas activas, pasivas, inflación, tipo de cambio) se relacionan con la trayectoria del crédito al sector privado.
 - b. En qué medida los modelos de machine learning aportan una mejora sustantiva sobre el enfoque econométrico tradicional.

- c. Cuáles son las implicaciones de estos resultados para el análisis de la transmisión de la política monetaria y la gestión del riesgo de crédito.

Esta fase integrará los hallazgos estadísticos con el marco teórico de la política monetaria y del canal del crédito bancario desarrollado en la literatura de banca y mercados financieros (Mishkin, 2022) y con la evidencia empírica reciente sobre el uso de algoritmos de machine learning en problemas de crédito y pronóstico financiero, donde se muestra que dichos modelos pueden complementar a los modelos econométricos clásicos en la toma de decisiones de instituciones financieras (W. O. Giraldo & Marín, 2021; Octavio & López, 2024).

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

En este capítulo se presentan y analizan los resultados empíricos de la investigación a partir del panel mensual de variables macrofinancieras oficiales del Banco Central de Honduras correspondiente al período 2010-01 a 2025-08, con el propósito de evaluar la capacidad predictiva de distintos enfoques aplicados al pronóstico del crédito bancario agregado al sector privado. Para ello, el capítulo se organiza como una secuencia analítica que parte del análisis exploratorio de datos, continúa con la descripción del proceso de recolección, depuración y preparación de la información, y culmina con la exposición de los resultados cuantitativos, el análisis estadístico y la comparación entre modelos econométricos y de machine learning. Esta estructura permite vincular la evidencia descriptiva con las decisiones metodológicas adoptadas y, al mismo tiempo, valorar de forma rigurosa si la incorporación de variables macrofinancieras mejora el pronóstico del crédito respecto a enfoques univariantes y si al menos un modelo de aprendizaje automático logra igualar o superar a los modelos econométricos de referencia bajo validación temporal estricta. En consecuencia, este capítulo constituye el núcleo empírico de la tesis, ya que documenta los hallazgos principales del estudio y sienta la base para la discusión, las conclusiones y las recomendaciones desarrolladas en el capítulo siguiente

4.1 ANÁLISIS EXPLORATORIO DE DATOS (EDA)

En esta sección se desarrolla el Análisis Exploratorio de Datos (EDA) sobre el panel mensual construido con series macrofinancieras oficiales del Banco Central de Honduras (BCH), con el objetivo de validar la integridad del conjunto de datos, describir su comportamiento estadístico y diagnosticar propiedades temporales y distribucionales relevantes para el pronóstico del crédito bancario. En contextos macrofinancieros, el EDA cumple una función forense: permite identificar tendencias, choques, persistencia, valores atípicos y posibles desviaciones de normalidad que condicionan la elección de transformaciones y la especificación de modelos econométricos y de machine learning.

El EDA se organiza en cuatro pasos: (4.1.1) caracterización del dataset y estadística descriptiva integral (incluyendo medidas de forma y normalidad), (4.1.2) depuración, transformaciones y pruebas preliminares de series de tiempo, (4.1.3) visualización para detectar patrones, outliers, correlaciones y memoria temporal, y (4.1.4) síntesis de hallazgos e

implicaciones metodológicas para el modelado posterior. Esta secuencia asegura que la modelación se apoye en evidencia descriptiva completa y en decisiones reproducibles.

4.1.1 DESCRIPCIÓN GENERAL DEL CONJUNTO DE DATOS

El análisis empírico se basa en un conjunto de datos de frecuencia mensual que integra series macrofinancieras vinculadas al crédito bancario al sector privado en Honduras, obtenidas del Banco Central de Honduras (BCH) mediante su portal de estadísticas y API pública. Conforme a la definición metodológica, la población se entiende como el proceso generador de datos del crédito y sus determinantes macrofinancieros; la evidencia empírica utilizada en esta investigación corresponde a la muestra analítica, definida como el recorte temporal en el cual todas las series pueden alinearse de forma consistente.

En consecuencia, la muestra del estudio abarca el período 2010-01 a 2025-08, conformado por $N = 188$ observaciones mensuales consecutivas, donde cada observación representa un mes y su correspondiente vector de variables macrofinancieras. La variable dependiente es el crédito total al sector privado del sistema financiero (EMF-AMCC-01, indicador 549). Como variables explicativas se emplean: tasa de política monetaria (EM-TPM-01, indicador 700), tipo de cambio nominal de venta (EC-TCN-01, indicador 620), tasa de interés activa en moneda nacional (EMF-TI-01, indicador 580), tasa de interés pasiva de ahorro en moneda nacional (EMF-TI-01, indicador 582) e inflación interanual (EP-IPC-01, indicador 609, variación interanual del IPC). La ILUSTRACIÓN 11 presenta la evolución conjunta de estas series en el período analizado, como caracterización visual preliminar del comportamiento del crédito y de su entorno macrofinanciero.

Todas las series se descargaron en formato homogéneo (.csv), con la estructura de campos definida por el BCH (Id, IndicadorId, Nombre, Descripción, Fecha, Valor). A partir de estos archivos se construyó un panel integrado denominado `bch_credito_panel_2010_2025`, con una fila por mes y una columna por variable. En esta etapa se verificó la consistencia de las fechas, la unicidad de los registros mensuales por indicador y la continuidad del intervalo 2010-01/2025-08. Como parte de la descripción general, se calcularon estadísticos descriptivos básicos para cada variable (media, mediana, desviación estándar, mínimo, máximo y percentiles), de modo que la Ilustración 4 sintetice los rangos y promedios del crédito y sus determinantes dentro del período completo (y, cuando corresponda, por subperíodos de interés). Estos resúmenes se obtuvieron con

rutinas reproducibles de análisis descriptivo en Python (`pandas.DataFrame.describe()`, `df.isna().sum()` (faltantes), `df.duplicated()` (duplicados), rango temporal: `df.index.min()` / `df.index.max()` o `Fecha.min/max`), coherentes con las prácticas estándar en análisis de datos macrofinancieros.

	n	media	desv_std	min	p05	p25	mediana	p75	p95	max
credito_sf_privado	188.0	349873.360266	176032.337232	137767.795000	140712.006115	205657.413750	309025.524450	435044.932250	708421.326790	742193.795800
tpm	188.0	0.050851	0.014161	0.030000	0.030000	0.037500	0.055000	0.060000	0.070000	0.070000
tcn_venta	188.0	22.810384	2.226556	18.976996	19.027197	20.726863	23.730515	24.683391	25.140946	26.319943
tasa_activa_mn	188.0	17.948714	1.945172	14.171600	14.313330	16.800000	18.205000	19.390000	20.703000	21.250000
tasa_pasiva_mn	188.0	3.288663	0.628790	2.120000	2.368210	2.551150	3.290000	3.882500	4.080000	4.200000
inflacion_ipc_interanual	188.0	4.965851	1.724574	2.100000	2.578500	3.947500	4.635000	5.672500	9.008000	10.860000
log_credito_sf_privado	188.0	12.640733	0.503445	11.833325	11.854455	12.233961	12.641139	12.983178	13.470776	13.517366
crec_mensual_credito	187.0	0.893604	0.635936	-0.624389	-0.033926	0.489799	0.834390	1.253330	1.994593	4.104390
crec_anual_credito	176.0	11.267172	3.489064	3.061422	4.495953	9.489928	11.250446	13.476463	16.799233	17.672723
delta_tpm	187.0	0.000067	0.002097	-0.007500	-0.001750	0.000000	0.000000	0.000000	0.000000	0.017500

Ilustración 4 Estadísticos descriptivos de las variables macrofinancieras (2010-01 a 2025-08)

Fuente: Elaboración propia con datos extraídos del API del BCH.

Además de los estadísticos descriptivos centrales, se incorporaron medidas de forma (asimetría y curtosis) y una prueba formal de normalidad (Shapiro–Wilk, Jarque Bera, Anderson) para cada variable. Este diagnóstico es relevante en series macrofinancieras porque la presencia de colas pesadas, asimetrías o desviaciones de normalidad puede afectar la interpretación paramétrica y justificar transformaciones de escala (logaritmos), así como la comparación de modelos bajo criterios de desempeño fuera de muestra.

Variable	N	Asimetria_skew	Curtosis_exceso	Shapiro_p	Decision_Shapiro	JarqueBera_p	Decision_JarqueBera	Anderson_A2	AD_crit_5pct	Decision_AD_5pct
crec_anual_credito_pct	176	-0.249	-0.376	4.577e-03	Rechaza normalidad	2.286e-01	No rechaza normalidad	0.831	0.770	Rechaza normalidad
crec_mensual_credito_pct	187	0.773	2.982	1.630e-04	Rechaza normalidad	1.000e-16	Rechaza normalidad	0.634	0.771	No rechaza normalidad
credito_sf_privado	188	0.754	-0.457	1.980e-09	Rechaza normalidad	6.434e-05	Rechaza normalidad	4.961	0.771	Rechaza normalidad
inflacion_ipc_interanual	188	1.321	2.129	3.702e-10	Rechaza normalidad	1.000e-16	Rechaza normalidad	5.259	0.771	Rechaza normalidad
log_credito_sf_privado	188	0.066	-1.086	1.356e-05	Rechaza normalidad	8.974e-03	Rechaza normalidad	1.724	0.771	Rechaza normalidad
tasa_activa_mn	188	-0.406	-0.803	3.030e-06	Rechaza normalidad	5.893e-03	Rechaza normalidad	2.372	0.771	Rechaza normalidad
tasa_pasiva_mn	188	-0.224	-1.434	2.680e-10	Rechaza normalidad	1.576e-04	Rechaza normalidad	6.926	0.771	Rechaza normalidad
tcn_venta	188	-0.556	-1.165	1.177e-11	Rechaza normalidad	4.165e-05	Rechaza normalidad	9.711	0.771	Rechaza normalidad
tpm	188	-0.284	-1.186	2.791e-11	Rechaza normalidad	1.160e-03	Rechaza normalidad	7.675	0.771	Rechaza normalidad

ILUSTRACIÓN 5 MEDIDAS DE FORMA Y PRUEBAS DE NORMALIDAD DE LAS VARIABLES (2010-01 A 2025-08)

Fuente: Elaboración propia con datos extraídos del API del BCH.

Los resultados evidencian desviaciones sistemáticas respecto a la normalidad en la mayoría de las series analizadas, lo cual es consistente con el comportamiento típico de variables macrofinancieras con tendencia, cambios de régimen y episodios de choque. En particular, el crédito en nivel presenta asimetría positiva y rechazo de normalidad en múltiples pruebas, mientras que la transformación logarítmica reduce sustancialmente la asimetría, aunque no garantiza normalidad estricta. Este diagnóstico justifica (i) priorizar transformaciones de escala (logaritmos y diferencias) y (ii) evaluar los modelos principalmente por desempeño fuera de muestra, además de considerar enfoques robustos y/o regularizados cuando existan colas pesadas o alta colinealidad.

A partir de este panel se generó un conjunto de variables derivadas utilizadas en los modelos econométricos y de machine learning. En particular, la variable dependiente se trabaja principalmente en logaritmos naturales (`log_credito_sf_privado`), lo que permite interpretar cambios en términos aproximados de variaciones porcentuales y contribuye a estabilizar la varianza. Adicionalmente, se construyeron tasas de crecimiento mensual y anual del crédito, así como transformaciones en diferencias o logaritmos de variables explicativas cuando fue pertinente, siguiendo la operacionalización establecida en los capítulos previos.

En el caso de los modelos econométricos multivariados, el conjunto se amplía con rezagos de las variables macrofinancieras seleccionadas. En la especificación SARIMAX y el modelo VAR se incorporan rezagos de la TPM, tasas de interés, inflación y tipo de cambio, de forma que la matriz de regresores se expande al incluir la dinámica temporal. De manera análoga, para los modelos de machine learning se construyen matrices de características con rezagos adicionales y combinaciones de las series base, manteniendo la consistencia temporal y el mismo horizonte muestral efectivo ($N=188$). De este modo, los resultados presentados en el capítulo descansan sobre una base única, depurada y documentada, construida exclusivamente a partir de estadísticas oficiales del BCH.

4.1.2 LIMPIEZA Y PREPARACIÓN DE LOS DATOS

La preparación del conjunto de datos siguió un flujo sistemático de depuración y transformación, coherente con las recomendaciones metodológicas para estudios cuantitativos con bases secundarias y series de tiempo. La tesis define previamente un procedimiento que va desde la descarga de las series oficiales del BCH hasta la conformación de una base integrada, la

verificación de consistencia y la generación de variables transformadas para el análisis econométrico y de aprendizaje automático. Esta lógica es congruente con la sugerencia de Hernández Sampieri et al. de asegurar, antes de modelar, la calidad, validez y confiabilidad de los datos obtenidos de archivos y bases institucionales.

En una primera etapa se integraron los archivos .CSV descargados desde la API del BCH en un panel mensual único. Se homogenizaron formatos de fecha, se ordenaron cronológicamente las observaciones y se verificó la unicidad de cada combinación indicador–mes, descartando duplicados y registros fuera del intervalo 2010-01/2025-08. Asimismo, se comprobó la ausencia de valores faltantes en el tramo de análisis, lo que permitió trabajar con la totalidad de las 188 observaciones sin aplicar procedimientos de imputación.

Posteriormente se realizó un filtrado específico de valores atípicos en las tasas de crecimiento del crédito y en la TPM, dado que los outliers pueden distorsionar la estimación de modelos de series de tiempo y de machine learning si no se documentan o tratan adecuadamente. Para ello se calcularon medidas robustas de dispersión (medianas y rangos intercuartílicos) sobre el crecimiento mensual y anual del crédito, así como sobre los cambios de la TPM, identificando observaciones que se ubicaban fuera de los intervalos habituales de variación. Estas observaciones no se eliminaron del conjunto de datos —pues corresponden a episodios macroeconómicos reales—, pero se marcaron explícitamente para su discusión posterior en el análisis y la validación de los modelos. La Ilustración 13 se sugiere en esta subsección para ilustrar gráficamente los puntos identificados como atípicos en el crecimiento del crédito y en la TPM.

Con el panel depurado se generaron luego las transformaciones propias del análisis de series de tiempo. En particular, se construyó el logaritmo natural del crédito total al sector privado {log_credito_sf_privado} y las tasas de crecimiento mensual y anual, además de mantener en niveles la TPM, la tasa de interés activa y pasiva, la inflación interanual y el tipo de cambio nominal. Estas transformaciones permiten interpretar los coeficientes como variaciones porcentuales aproximadas y contribuyen a estabilizar la varianza de las series, lo cual es un requisito habitual en la modelación econométrica de series macroeconómicas.

A continuación, se evaluó la propiedad de estacionariedad mediante pruebas de raíces unitarias del tipo Dickey–Fuller aumentado (ADF) aplicadas a cada serie en niveles y, cuando fue

pertinente, a sus primeras diferencias. Los resultados (Ilustración 17) muestran, en términos generales, que el crédito y las principales variables monetarias presentan comportamiento integrado de orden uno (I(1)) en niveles, mientras que sus primeras diferencias tienden a ser estacionarias. Esta evidencia orientó la especificación de los modelos ARIMA/SARIMAX y VAR, así como la elección de trabajar con logaritmos y rezagos en los modelos de machine learning.

Finalmente, para la etapa de modelado se prepararon matrices de diseño específicas para cada familia de modelos. En los modelos econométricos se generaron rezagos de las variables macrofinancieras (TPM, tasas de interés, inflación y tipo de cambio) hasta el orden definido en los criterios de información, con el fin de capturar la dinámica temporal y los efectos retardados de la política monetaria. En los modelos de machine learning, además de los rezagos, se aplicó estandarización de las variables explicativas mediante *StandardScaler* para evitar que las diferencias de escala influyeran en la estimación de los parámetros, siguiendo buenas prácticas de preprocesamiento en problemas de pronóstico financiero con ML. En todos los casos, la partición temporal entre muestras de entrenamiento y prueba respetó la secuencia cronológica del periodo 2010-01/2025-08, garantizando que la evaluación de los modelos se realice sobre información verdaderamente fuera de muestra.

4.1.3 VISUALIZACIÓN DE DATOS

Antes de la estimación de los modelos econométricos y de aprendizaje automático, se realizó un análisis exploratorio apoyado en técnicas de visualización, con el propósito de caracterizar la dinámica temporal del crédito y su relación con la política monetaria y el entorno macroeconómico. En estudios cuantitativos, la representación gráfica de las series mediante gráficos de líneas, tasas de variación y diagramas de dispersión constituye el primer paso para comprender patrones, cambios de régimen y posibles anomalías en los datos (Banco Central de Honduras, 2024a). Esta práctica es consistente con las recomendaciones de la literatura de metodología de la investigación, que plantea el análisis descriptivo y gráfico como etapa previa indispensable al uso de técnicas inferenciales avanzadas (Banco Central de Honduras, 2024a).

En primer lugar, se emplearon gráficos de líneas para representar la trayectoria mensual del crédito total al sector privado y de las principales variables macrofinancieras en el período 2010-01 / 2025-08. La ILUSTRACIÓN 11 correspondiente muestra, en paneles diferenciados, la

evolución conjunta del nivel de crédito y de la tasa de política monetaria, así como las tasas de crecimiento mensual y anual del crédito, la tasa de interés activa en moneda nacional, la inflación interanual del IPC y el tipo de cambio nominal de venta. Este conjunto de gráficos permite identificar de forma visual una tendencia creciente y relativamente suave del crédito, episodios de aceleración (en la fase de recuperación posterior a la pandemia de COVID-19) y periodos de endurecimiento y relajación de la política monetaria que se reflejan en cambios escalonados de la TPM. Asimismo, se observan choques inflacionarios relevantes y una trayectoria persistentemente depreciatoria del tipo de cambio.

En segundo término, se construyeron matrices de correlación entre las variables en niveles y entre el crecimiento mensual del crédito y las variables macrofinancieras. Los mapas de calor permiten sintetizar visualmente la intensidad y el signo de las correlaciones de Pearson, destacando, en el caso de las series en niveles, una asociación negativa elevada entre el logaritmo del crédito y las tasas de interés activa y pasiva en moneda nacional, así como una correlación positiva muy fuerte entre el crédito y el tipo de cambio nominal de venta. En contraste, la inflación interanual presenta una correlación cercana a cero con el nivel del crédito, pero una correlación positiva moderada con el crecimiento mensual del mismo. Estas matrices sirven como insumo para la especificación de los modelos, al sugerir qué relaciones son potencialmente relevantes y dónde podrían existir problemas de multicolinealidad, especialmente entre las tasas de interés, como podemos ver en la Ilustración 6.

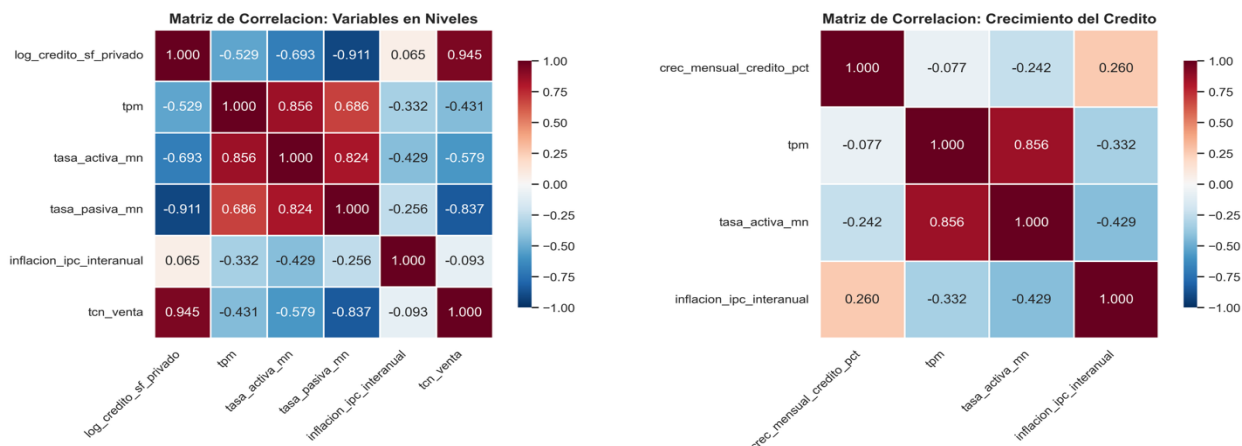


ILUSTRACIÓN 6 Matrices de correlación

Fuente: Elaboración propia con datos extraídos del API del BCH.

A nivel distribucional, se incorporó un bloque de verificación forense de supuestos paramétricos mediante gráficos Q–Q y contrastes visuales por periodos (Pre-COVID, COVID y Post-COVID). Los Q–Q plots evidencian que el crédito en nivel presenta desviaciones sistemáticas respecto a la normalidad, particularmente en colas y en la parte alta de la distribución, consistentes con asimetrías y colas pesadas típicas de series macrofinancieras. Al aplicar la transformación logarítmica, la distribución del crédito se aproxima parcialmente al patrón lineal esperado bajo normalidad (reduciendo la curvatura central y moderando extremos), aunque persisten desviaciones en colas, lo que sugiere que la normalidad estricta no se cumple plenamente. Esta lectura se refuerza con el contraste KDE vs. Normal teórica, donde la densidad empírica del crédito (nivel) se separa de la campana normal y el log(crédito) muestra un ajuste visual superior pero todavía imperfecto. Complementariamente, los boxplots por periodos permiten identificar cambios de régimen asociados a la pandemia: tanto la dispersión del log(crédito) como la distribución de la TPM difieren entre subperiodos, lo cual respalda la conveniencia de documentar shocks y trabajar con especificaciones robustas (transformaciones, regularización y evaluación fuera de muestra) antes del modelado predictivo.

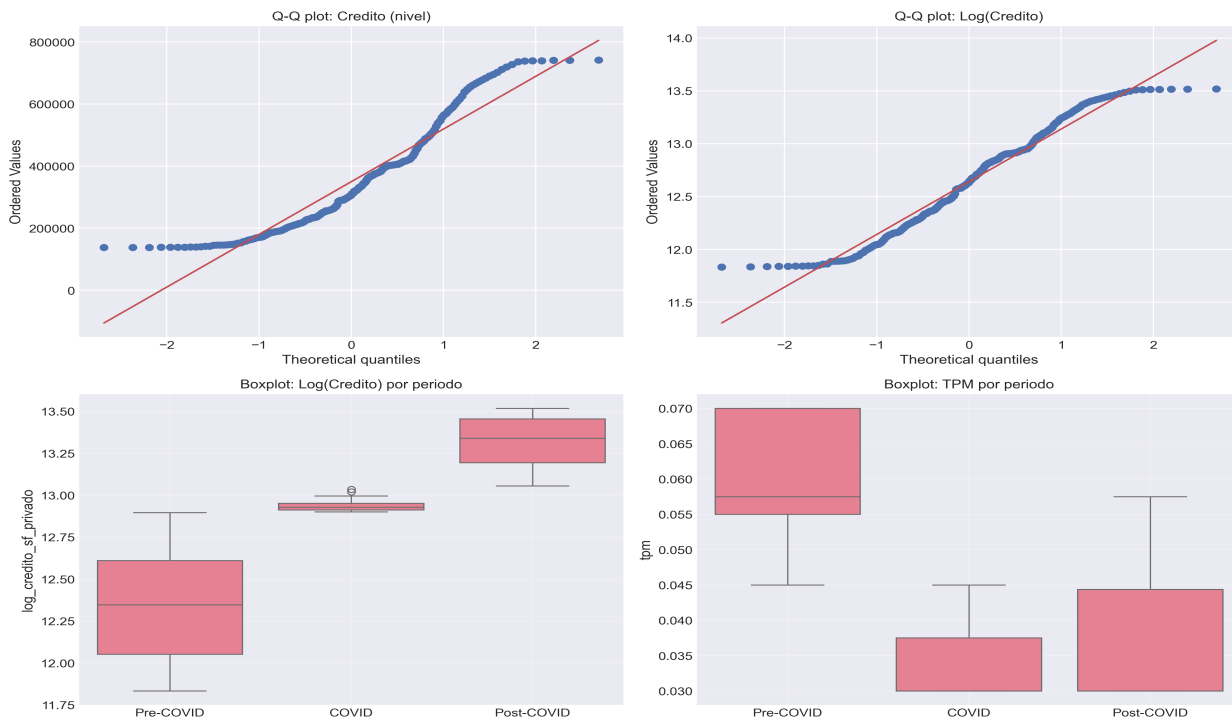


Ilustración 7 Figura FORENCE QQ BOX pre y post COVID

Fuente: Elaboración propia con datos extraídos del API del BCH.

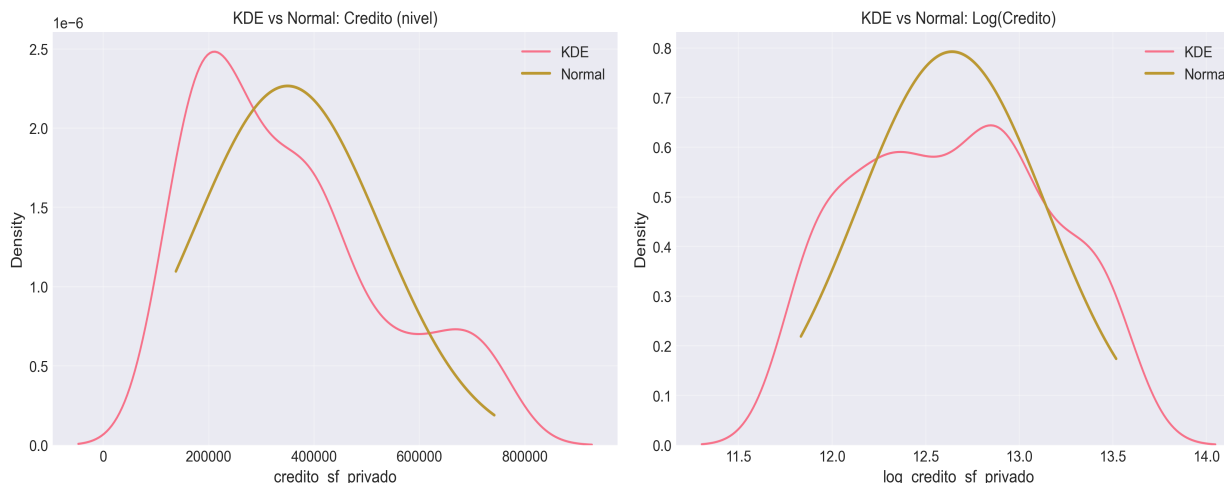


Ilustración 8 KDE vs normal crédito nivel vs log

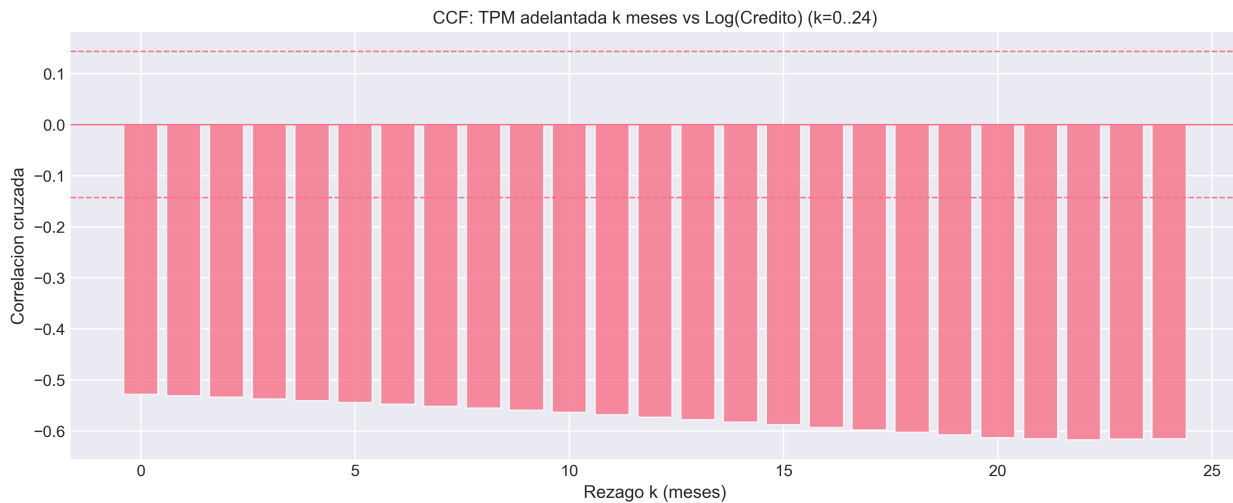
Fuente: Elaboración propia con datos extraídos del API del BCH.

En paralelo, se evaluó la relación dinámica entre política monetaria y crédito mediante correlación cruzada (CCF) con rezagos, utilizando la TPM adelantada k meses frente a $\log(\text{crédito})$ para $k=0..24$.

Los resultados muestran una asociación contemporánea y rezagada que se mantiene en forma persistente en el horizonte analizado, lo que es coherente con la idea de transmisión monetaria con rezagos: cambios en la postura de política monetaria se reflejan gradualmente en condiciones financieras y, en última instancia, en el crédito.

Dado que las correlaciones entre series en nivel pueden estar influidas por tendencia común y alta persistencia, se incluye adicionalmente una versión robusta de la CCF sobre primeras diferencias ($\Delta(\text{TPM})$ vs. $\Delta(\log(\text{crédito}))$), la cual permite observar la relación en cambios marginales y reduce el riesgo de asociaciones espurias por no estacionariedad.

En conjunto, este bloque visual confirma (i) la presencia de no normalidad y posibles colas pesadas, (ii) diferencias de distribución por periodos macroeconómicos relevantes, y (iii) dependencia temporal entre TPM y crédito, elementos que justifican el uso de transformaciones (log), selección cuidadosa de rezagos, y modelos con regularización y validación estrictamente temporal en las secciones de modelado posteriores.



Rezago	CCF_TPM_to_LogCredito	Limite_95	Significativo_95
0	-0.528606	0.142948	Si
1	-0.531181	0.142948	Si
2	-0.533997	0.142948	Si
3	-0.537187	0.142948	Si
4	-0.540497	0.142948	Si
5	-0.544022	0.142948	Si
6	-0.547666	0.142948	Si
7	-0.551517	0.142948	Si
8	-0.555373	0.142948	Si
9	-0.559521	0.142948	Si

Ilustración 9 CCF logaritmo del TPM (KDE = 0.24)

Fuente: Elaboración propia con datos extraídos del API del BCH.

Finalmente, se recurrió a correlogramas (función de autocorrelación y autocorrelación parcial) para las principales series de política monetaria y de crédito. En ILUSTRACIÓN 10 los gráficos de ACF y PACF evidencian una fuerte persistencia serial, particularmente en la TPM, cuyo correlograma muestra un decaimiento lento de las autocorrelaciones y picos significativos en los primeros rezagos.

Este patrón es consistente con el carácter altamente inercial de la política monetaria documentado en la literatura para economías emergentes, donde los bancos centrales ajustan sus tasas de referencia de manera gradual y con rezago (Banco Central de Honduras, 2024a). La información de los correlogramas se utiliza posteriormente para justificar la inclusión de rezagos

en los modelos ARIMA/SARIMAX y VAR, pero en esta sección se presenta como parte del análisis descriptivo de la memoria temporal de las series.




Ilustración 10 diagramas acf y pacf

Fuente: Elaboración propia con datos extraídos del API del BCH.

4.1.4 CONCLUSIONES DEL EDA

A partir del análisis exploratorio del panel mensual (2010-01 a 2025-08, N=188), se identificaron patrones estadísticos y temporales que condicionan de forma directa las decisiones de transformación, especificación y validación de los modelos econométricos y de machine learning utilizados en los apartados posteriores.

En primer lugar, el diagnóstico distribucional confirma que las variables macrofinancieras no siguen normalidad en el sentido paramétrico clásico. La matriz de forma y normalidad (asimetría, curtosis y pruebas Shapiro–Wilk, Jarque–Bera y Anderson–Darling) evidencia p-valores extremadamente bajos para la mayoría de las series en nivel, incluyendo el crédito y la TPM, por lo que se rechaza normalidad de manera sistemática. Este resultado es coherente con los Q-Q plots y con el contraste KDE vs Normal, donde se observan desviaciones en colas y curvaturas respecto a la distribución gaussiana teórica. Incluso tras aplicar la transformación logarítmica al crédito, la aproximación mejora visualmente, pero el rechazo formal persiste, lo cual es consistente con el carácter asimétrico y con colas pesadas típico en series macrofinancieras. En consecuencia, la comparación de modelos se fundamenta principalmente en desempeño fuera de muestra y en métricas de error, y se justifica la incorporación de transformaciones (logaritmos/diferencias) y enfoques robustos (regularización y validación temporal) para mitigar el impacto de no normalidad y heterogeneidad en varianzas.

En segundo lugar, el análisis de correlación en niveles muestra un entorno con dependencia lineal elevada y potencial multicolinealidad entre predictores monetarios (asociación fuerte entre tasas) y relaciones relevantes entre el crédito y variables del entorno macrofinanciero. Estos hallazgos refuerzan la necesidad de: (i) evitar especificaciones con regresores altamente redundantes sin control, y (ii) privilegiar enfoques de selección/penalización (Ridge/Lasso) y/o especificaciones parsimoniosas en modelos multivariados, para estabilizar estimaciones y prevenir sobreajuste.

En tercer lugar, las visualizaciones por periodos Pre-COVID / COVID / Post-COVID (boxplots) muestran cambios en niveles y dispersión (particularmente en TPM y en el crédito transformado), lo que sugiere cambios de régimen y/o heterocedasticidad por etapas. Esto implica que la evaluación debe respetar la secuencia temporal (train/test cronológico) y que conviene incorporar diagnósticos y validaciones que contemplen episodios de choque, evitando conclusiones basadas únicamente en promedios globales.

Finalmente, el análisis dinámico mediante correlación cruzada aporta evidencia clave sobre la relación TPM-crédito. La CCF en niveles entre TPM y $\log(\text{crédito})$ muestra una correlación negativa significativa para rezagos 0–24 meses; sin embargo, este patrón puede estar influido por tendencias comunes y persistencia temporal en series en nivel. Por ello, el contraste robusto en diferencias ($\Delta(\text{TPM})$ vs $\Delta(\log(\text{crédito}))$) resulta crítico: aquí se observa significancia puntual en el rezago $k=0$ y $k=2$ (por encima del umbral al 95%), mientras el resto de los rezagos pierde significancia. Este hallazgo sugiere que el vínculo dinámico más defendible estadísticamente está asociado a respuestas contemporáneas o de muy corto plazo cuando se controla por tendencia/persistencia, y guía la modelación posterior hacia: (i) uso de transformaciones estacionarias (diferencias/log-diferencias) para inferencia temporal, (ii) incorporación de rezagos acotados y justificados por evidencia, y (iii) comparación entre modelos que capturen memoria corta vs memoria larga (ARIMA/SARIMAX/VAR frente a ML con variables rezagadas).

En síntesis, el EDA concluye que el problema presenta: (a) no normalidad y colas pesadas, (b) multicolinealidad en predictores monetarios, (c) posibles cambios de régimen por etapas (COVID), y (d) relación TPM-crédito con señal fuerte en niveles, pero más selectiva en

diferencias. Por tanto, el modelado subsecuente debe apoyarse en transformaciones (log/diferencias), control de colinealidad (regularización/selección), validación temporal estricta y evaluación por desempeño predictivo fuera de muestra, garantizando coherencia entre evidencia descriptiva y decisiones metodológicas.

4.2 INFORME DEL PROCESO DE RECOLECCIÓN DE DATOS

4.2.1 DESCRIPCIÓN DEL PROCESO DE RECOLECCIÓN

La recolección de datos se realizó exclusivamente a partir de fuentes secundarias oficiales, siguiendo la recomendación de la metodología cuantitativa de definir de antemano las fuentes, el procedimiento y los criterios de calidad de la información antes de iniciar el análisis estadístico (Hernández Sampieri et al., 2006). En este sentido, se utilizaron las series mensuales publicadas por el Banco Central de Honduras (BCH) a través de su portal de estadísticas y de la interfaz de programación de aplicaciones (API) institucional, lo que garantiza trazabilidad, replicabilidad y consistencia con la información utilizada en los informes oficiales de política económica.

En una primera etapa se definió el universo de variables a recolectar, de acuerdo con la operacionalización presentada en el capítulo III: (i) crédito total del sistema financiero al sector privado (grupo EMF-AMCC-01, indicador 549), (ii) tasa de política monetaria (EM-TPM-01_700), (iii) tasa de interés activa promedio en moneda nacional (EMF-TI-01_580), (iv) tasa de interés pasiva de ahorro en moneda nacional (EMF-TI-01_582), (v) inflación interanual del índice de precios al consumidor (EP-IPC-01_609) y (vi) tipo de cambio nominal de venta (EC-TCN-01_620). Para cada indicador se establecieron la frecuencia mensual, el periodo de cobertura (2010-01 a 2025-08) y la unidad de medida, conforme a las fichas técnicas del BCH.

En una segunda etapa se procedió a la descarga sistemática de las series mediante rutinas automatizadas en Python, que consultan la API del BCH y generan archivos en formato .csv con una estructura homogénea (Fecha, Valor) por indicador. Los archivos descargados se almacenaron en un repositorio único y posteriormente se integraron en una base maestra de trabajo denominada `bch_credito_panel_2010_2025`, en la que cada fila corresponde a un mes del periodo de estudio y cada columna a una variable macrofinanciera. Esta integración implicó la homologación de

formatos de fecha, la verificación de la unicidad de los registros mensuales y la comprobación de que todas las series contaran con observaciones continuas en el horizonte analizado.

En una tercera etapa se aplicó un procedimiento de control de calidad, que consistió en contrastar la evolución de las series construidas con las cifras publicadas en los documentos institucionales del BCH como la Memoria Anual y el Informe de Estabilidad Financiera, verificando que los niveles y trayectorias del crédito, las tasas de interés, la inflación y la tasa de política monetaria coincidieran con los agregados que utiliza la autoridad monetaria para el seguimiento de la estabilidad macrofinanciera. Cualquier discrepancia potencial se revisó a la luz de las notas metodológicas del propio BCH antes de validar definitivamente la base.

4.2.2 PARTICIPANTES O FUENTES DE INFORMACIÓN

En esta investigación se emplean de manera articulada fuentes de información primarias y secundarias, con el fin de asegurar, por un lado, la solidez empírica de los datos utilizados en la modelización y, por otro, un sustento conceptual y metodológico consistente con la literatura especializada. Se entiende por fuentes primarias aquellos datos originales que representan directamente el fenómeno de estudio, mientras que las fuentes secundarias corresponden a trabajos que sistematizan, interpretan o analizan información previamente recopilada, tales como libros, artículos científicos, reportes institucionales y documentos normativos (Hernández Sampieri et al., 2006).

Las fuentes primarias están constituidas por las series mensuales oficiales del Banco Central de Honduras (BCH) y de la Comisión Nacional de Bancos y Seguros (CNBS). En particular, se utilizan los registros del crédito total al sector privado del sistema financiero, la tasa de política monetaria, la tasa de interés activa y pasiva, el tipo de cambio nominal de venta y la inflación interanual derivada del índice de precios al consumidor. Estas series se obtienen mediante la API pública del BCH y se contrastan con las estadísticas publicadas en documentos como la Memoria Anual 2024 y el Informe de Estabilidad Financiera (IEF), donde se reportan los mismos agregados y se explicita que la información proviene de los departamentos técnicos del Banco Central y de la CNBS, lo que refuerza su carácter oficial y validado.

Operativamente, cada serie se descargó en formato homogéneo (.csv) a partir de la API del BCH respetando la estructura de campos Id, IndicadorId, Fecha y Valor y posteriormente se

integró en un panel mensual único que abarca el período 2010-01 a 2025-08. Este procedimiento permite trabajar con una base consolidada de 188 observaciones consecutivas, sobre la cual se construyen las transformaciones y rezagos utilizados en los modelos econométricos (ARIMA/SARIMAX y VAR) y en los algoritmos de machine learning (regresiones penalizadas y otros estimadores lineales).

Las fuentes secundarias incluyen textos de metodología de la investigación, teoría monetaria y bancaria, econometría y machine learning, así como estudios empíricos recientes sobre pronóstico macroeconómico y del crédito bancario. Destacan, entre otros, la obra de Hernández Sampieri et al. (2006) para la fundamentación del enfoque cuantitativo; los desarrollos de Mishkin sobre la transmisión de la política monetaria y el canal del crédito bancario; los manuales de Greene en econometría, que respaldan el uso de modelos de series de tiempo y estructuras dinámicas; y trabajos que comparan modelos tradicionales (ARIMA, VAR, regresión lineal) con algoritmos de machine learning en la predicción de variables macrofinancieras.

4.2.3 INSTRUMENTOS UTILIZADOS

En esta investigación los instrumentos no son cuestionarios ni escalas aplicadas a personas, sino dispositivos documentales y computacionales que norman la medición de las variables, organizan el registro de la información y permiten reproducir el análisis empírico. De acuerdo con la literatura metodológica, un instrumento es el medio concreto mediante el cual se observan y registran las variables definidas en la matriz de operacionalización, y su adecuada documentación contribuye tanto a la validez de contenido como a la confiabilidad de los resultados.

a) Matriz de operacionalización y diccionario de datos:

El primer instrumento está conformado por la matriz de operacionalización de variables y el diccionario de datos asociado. La matriz traduce cada constructo teórico (crédito bancario al sector privado, condiciones monetarias, entorno macroeconómico) en indicadores observables, especificando para cada uno: definición conceptual y operativa, unidad de medida, escala, período de cobertura, frecuencia, fuente exacta en los sistemas estadísticos del BCH y rol en el modelo (variable dependiente, explicativa o de control).

El diccionario de datos complementa esta matriz describiendo, para cada columna de la base de datos maestra, el nombre corto utilizado en los archivos y en el código, la descripción conceptual, el período de cobertura, las transformaciones aplicadas (logaritmos o diferencias) y eventuales advertencias metodológicas (cambios de año base, reclasificaciones). Ambos documentos funcionan como instrumentos que norman la medición y facilitan que terceros puedan entender, replicar y auditar el proceso, reforzando la validez de contenido y la confiabilidad al reducir la improvisación y los errores de interpretación de las series.

b) Cuadernos de trabajo (notebooks) en Python:

El segundo instrumento lo constituyen los cuadernos de trabajo en Python (notebooks 01 a 05), en los que se implementa de manera estructurada y reproducible todo el flujo del análisis empírico: carga y depuración de los archivos CSV descargados vía API del BCH, integración de las series en el panel maestro, generación de estadísticas descriptivas y visualizaciones, estimación del modelo econométrico de referencia, entrenamiento de los modelos de machine learning y cálculo de métricas de desempeño de pronósticos.

En la práctica profesional de ciencia de datos, este tipo de cuadernos se considera parte del “instrumental” analítico, pues concentran las fases de comprensión de los datos, preparación, modelado y evaluación que propone la metodología CRISP-DM para proyectos de minería de datos y analítica avanzada. Estudios recientes sobre machine learning aplicado a riesgo de crédito y estimación de ingresos en instituciones financieras latinoamericanas también utilizan bases de datos tabulares y notebooks en Python o R como soporte formal de los modelos, enfatizando la importancia de documentar el flujo de trabajo para garantizar la reproducibilidad y la trazabilidad de las decisiones de preprocesamiento y modelado.

c) Esquemas de validación y plantillas de resultados

El tercer instrumento está formado por los scripts y plantillas que organizan la validación de los modelos y la presentación de resultados. En particular, se diseñaron rutinas que generan de forma automática: (i) tablas comparativas con las métricas de error (RMSE, MAE, MAPE, R^2) para cada modelo y horizonte de pronóstico, (ii) gráficos de valores observados frente a predicciones en el tramo de prueba y sobre la serie completa, y (iii) resúmenes tabulares que

permiten contrastar, de manera estandarizada, el desempeño del modelo econométrico de referencia frente a los modelos de machine learning e híbridos.

4.2.4 DIFICULTADES ENCONTRADAS

Durante el proceso de recolección, depuración y modelización de los datos se presentaron diversas dificultades técnicas y metodológicas que fue necesario abordar de manera sistemática para garantizar la calidad de los resultados, en consonancia con las recomendaciones de la literatura de metodología de la investigación y econometría aplicada.

En primer lugar, el esquema de provisión de datos del Banco Central de Honduras (BCH) a través de su API supuso un reto operativo. Cada serie se consulta mediante identificadores específicos y se descarga en archivos separados, por lo que fue necesario programar rutinas en Python que gestionaran múltiples llamadas, verificaran la estructura homogénea de columnas y consolidaran los archivos en un panel único. Este procedimiento implicó manejar diferencias en nombres de variables, descriptores y metadatos, así como controlar la aparición de registros duplicados o fechas inconsistentes antes de construir el conjunto integrado `bch_credito_panel_2010_2025`.

En segundo lugar, se enfrentaron problemas de alineación temporal entre las distintas series macrofinancieras. Algunas variables iniciaban en fechas distintas o presentaban cambios de cobertura a lo largo del tiempo, lo que obligó a truncar el análisis al tramo común 2010-01/2025-08 y a verificar la ausencia de huecos en la frecuencia mensual. Esta decisión redujo el número de observaciones potenciales, lo que genera una tensión conocida en econometría de series de tiempo: la necesidad de contar con un horizonte suficientemente largo para capturar la dinámica, pero al mismo tiempo evitar quiebres estructurales y cambios de definición que contaminen la muestra.

Una tercera dificultad estuvo relacionada con las propiedades estocásticas de las series. El crédito al sector privado, el tipo de cambio y algunas tasas de interés presentan tendencias marcadas y alta persistencia, características que, de no tratarse adecuadamente, pueden conducir a problemas de no estacionariedad y regresiones espurias. La literatura enfatiza que la identificación de raíces unitarias y la aplicación de pruebas como Dickey–Fuller aumentada o KPSS son pasos indispensables antes de especificar modelos ARIMA, VAR o SARIMAX. En la práctica, esto exigió iterar entre pruebas formales y análisis gráfico (funciones de autocorrelación,

descomposición de la serie) hasta encontrar transformaciones y órdenes de rezagos compatibles con los supuestos de los modelos. Además, en algunos casos los algoritmos de estimación presentaron problemas de convergencia para ciertas combinaciones de parámetros, lo que obligó a restringir el espacio de búsqueda y adoptar especificaciones parsimoniosas, tal como sugieren los manuales de econometría aplicada.

Asimismo, el análisis exploratorio reveló observaciones atípicas asociadas a episodios específicos como cambios abruptos en el crecimiento del crédito o picos de inflación que afectaban de manera sensible las estimaciones y los diagnósticos de normalidad de los residuos. La detección de estos outliers y su tratamiento (vía contextualización económica, contrastes de robustez y, cuando fue necesario, exclusión controlada en pruebas de sensibilidad) supuso un trabajo adicional de documentación y validación de resultados, en línea con la recomendación de no depender exclusivamente de procedimientos automáticos sino complementar con juicio sustantivo.

Finalmente, la incorporación de técnicas de machine learning introdujo desafíos adicionales vinculados a la alta dimensionalidad y a la colinealidad entre predictores. La fuerte correlación entre la tasa de política monetaria y las tasas activa y pasiva, así como entre el nivel del crédito y el tipo de cambio, exigió recurrir a métodos de regularización (Ridge y Lasso) y a validación cruzada para evitar sobreajuste y mejorar la interpretabilidad de los modelos, siguiendo las recomendaciones de la literatura reciente sobre predicción macroeconómica con muchos predictores.

En conjunto, estas dificultades no invalidan los resultados, pero sí contextualizan el esfuerzo realizado para asegurar que las conclusiones del capítulo descansen en un proceso de recolección y tratamiento de datos transparente, replicable y consistente con los estándares metodológicos de la investigación cuantitativa.

4.2.5 CONSIDERACIONES ÉTICAS

En esta investigación se asumió explícitamente un compromiso con los principios éticos propios de los estudios cuantitativos en ciencias sociales: respeto a las fuentes de información, integridad en el manejo y análisis de los datos, y transparencia en la comunicación de resultados (Hernández Sampieri & Mendoza Torres, 2018). Dado que el estudio se basa exclusivamente en series estadísticas agregadas y de carácter público, no se involucró la participación directa de

personas ni el levantamiento de datos sensibles a nivel individual, por lo que no fue necesario recabar consentimientos informados ni someter protocolos de intervención con sujetos humanos.

Las series utilizadas corresponden a estadísticas oficiales del Banco Central de Honduras (BCH), consideradas en esta tesis como fuentes primarias en la medida en que constituyen mediciones originales y sistemáticas de las variables macrofinancieras de interés. [OBJ] Todas ellas se emplean respetando los términos de uso institucionales y citando al BCH como propietario y responsable de la generación de la información. El hecho de trabajar con datos agregados como el crédito total al sector privado o la TPM garantiza que no sea posible identificar a personas naturales ni a entidades financieras específicas, por lo que se salvaguarda la confidencialidad y el anonimato.

En el tratamiento de los datos se procuró mantener la integridad de la información original: las transformaciones aplicadas (logaritmos, tasas de crecimiento, rezagos, pruebas de estacionariedad, etc.) se documentan de forma explícita en los cuadernos de trabajo y en la descripción metodológica del capítulo, evitando cualquier manipulación que pudiera distorsionar los resultados. Esta práctica es coherente con el criterio de rigor y trazabilidad que la literatura de metodología cuantitativa plantea para garantizar la validez interna y externa de los estudios.

Asimismo, los modelos econométricos y de machine learning se evaluaron y reportaron de manera objetiva, presentando tanto los desempeños favorables como las limitaciones de cada especificación. No se ocultaron resultados que fueran menos favorables a la hipótesis planteada, ni se realizó selección ex post de modelos con el objetivo exclusivo de maximizar indicadores de ajuste. Este enfoque busca reducir sesgos de confirmación y se alinea con las buenas prácticas de investigación empírica en economía y finanzas.

Finalmente, se aclara que las proyecciones generadas en esta tesis tienen un propósito estrictamente académico y no constituyen recomendaciones de política monetaria, lineamientos regulatorios ni orientaciones de crédito para el público.

La interpretación de los resultados se realiza siempre en el marco del mandato legal del BCH como autoridad monetaria y del sistema financiero hondureño, sin atribuir a la institución posiciones que no hayan sido expresamente publicadas por ella.

4.3 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS

La presente sección expone los hallazgos derivados del procesamiento y análisis de los datos recopilados del Banco Central de Honduras (BCH), correspondientes al período comprendido entre enero de 2010 y agosto de 2025. El análisis integra técnicas de econometría clásica y algoritmos de machine learning para evaluar la capacidad predictiva de distintos enfoques metodológicos aplicados al pronóstico del crédito bancario hondureño al sector privado.

4.3.1 RESULTADOS CUANTITATIVOS

4.3.1.1 PRESENTACIÓN DE LOS DATOS

El análisis cuantitativo se fundamenta en un panel de series macrofinancieras de frecuencia mensual, construido a partir de estadísticas oficiales del Banco Central de Honduras (BCH). La muestra abarca el período enero de 2010 a agosto de 2025, con $N = 188$ observaciones consecutivas, donde cada observación representa un mes y su vector asociado de variables macrofinancieras. La base se organizó en formato tabular, con el tiempo como índice (fecha mensual) y una columna por variable.

La variable dependiente del estudio es el crédito total al sector privado del sistema financiero. Como variables explicativas se emplean la Tasa de Política Monetaria (TPM), el tipo de cambio nominal de venta, la tasa de interés activa en moneda nacional, la tasa de interés pasiva de ahorro en moneda nacional y la inflación interanual del IPC. La TABLA 12 presenta la descripción operativa de las variables incluidas, sus unidades de medida y el identificador correspondiente en las series oficiales del BCH.

Tabla 12 Descripción de las variables del estudio

Variable	Descripción	Unidad	Fuente
Crédito al Sector Privado	Saldo total del crédito otorgado por el sistema financiero privado	Millones de Lempiras	BCH (Serie 549)
Tasa de Política Monetaria (TPM)	Tasa de interés de referencia establecida por el BCH	Porcentaje	BCH (Serie 700)
Tasa Activa en Moneda Nacional	Tasa promedio ponderada de préstamos	Porcentaje	BCH (Serie 580)
Tasa Pasiva de Ahorro MN	Tasa promedio de depósitos de ahorro	Porcentaje	BCH (Serie 582)

Inflación Interanual (IPC)	Variación porcentual del índice de precios al consumidor	Porcentaje	BCH (Serie 609)
Tipo de Cambio Nominal (TCN)	Tasa de cambio de venta Lempira/Dólar	Lempiras por USD	BCH (Serie 620)

Fuente: Elaboración propia con datos del Banco Central de Honduras.

Para caracterizar el panel y documentar su estructura, se reportan estadísticos descriptivos del período completo. La TABLA 13 resume, para cada variable, medidas de tendencia central y dispersión (media y desviación estándar), así como valores extremos (mínimo y máximo) y el número de observaciones válidas. Este resumen cumple una función descriptiva inicial: delimita magnitudes típicas, rangos de variación y escalas comparables entre variables, y facilita la verificación de consistencia del panel antes de la aplicación de pruebas estadísticas e inferenciales.

La evolución temporal conjunta de las series se presenta mediante la ILUSTRACIÓN 11, que muestra las trayectorias mensuales del crédito y de los principales determinantes macrofinancieros en el horizonte 2010–2025. Esta visualización permite documentar la forma general de las series (tendencias, cambios de nivel y episodios de volatilidad), sin anticipar interpretaciones causales o conclusiones econométricas, las cuales se desarrollan en las subsecciones posteriores.

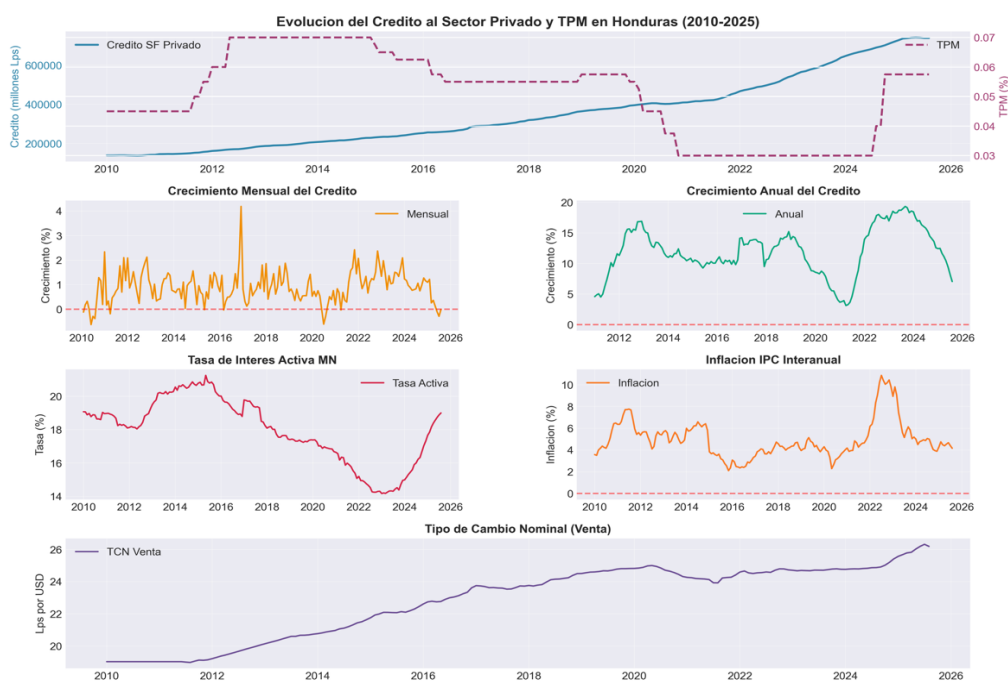


Ilustración 11 Evolución del crédito al sector privado y TPM en Honduras

Fuente: Elaboración propia con datos extraídos del API del BCH.

Tabla 13 Estadísticas descriptivas del panel de datos (2010 - 2025)

Estadístico	Crédito (Millones L.)	TPM (%)	Tasa Activa (%)	Tasa Pasiva (%)	Inflación (%)	TCN (L./USD)
Media	368,363.52	5.17	18.59	3.80	4.69	22.45
Desv. Estándar	177,461.89	1.28	1.06	0.52	1.54	2.64
Mínimo	137,767.80	3.00	15.87	2.50	2.29	19.03
Máximo	739,231.51	7.00	20.28	4.20	9.09	26.32
Observaciones	188	188	188	188	188	188

Fuente: Elaboración propia con datos extraídos del API del BCH.

Tabla 14 Análisis comparativo por períodos económicos

Período	Observaciones	Crédito Promedio (Millones L.)	TPM Promedio (%)	Crecimiento Mensual Promedio (%)	Volatilidad	Correlación TPM-Crédito
Pre-COVID (2010-2019)	120	238,874.79	5.88	0.88	0.65	0.137
COVID (2020-2021)	24	415,219.03	3.60	0.63	0.67	-0.654
Post-COVID (2022-2024)	36	589,995.54	3.28	1.27	0.42	0.518

Fuente: Elaboración propia con datos extraídos del API del BCH.

La TABLA 14 para efectos de reporte descriptivo por contexto macroeconómico, el período de estudio se segmenta en tres subperíodos de referencia: Pre-COVID (2010–2019), COVID (2020–2021) y Post-COVID (2022–2025). Esta segmentación se utiliza únicamente como criterio de organización de resultados en tablas y figuras; el contraste formal entre subperíodos y la evaluación estadística de diferencias se presenta más adelante en el apartado de análisis estadístico.

4.3.1.2 DESCRIPCIÓN DE LOS HALLAZGOS

En el período 2010-01 a 2025-08, el crédito al sector privado muestra una trayectoria de crecimiento nominal sostenido. De acuerdo con el resumen de crecimiento (Ilustración 12), el saldo pasa de L. 139,013.61 millones (2010-01) a L. 739,231.51 millones (2025-08). Esto equivale a un incremento acumulado de 431.8% y una tasa de crecimiento anual compuesta (CAGR) de 11.34% (CAGR mensual \approx 0.90%). En términos de dinámica de corto y mediano plazo, el mismo archivo reporta que el crecimiento mensual del crédito presenta una media de 0.928% (mediana 0.888%, desviación estándar 0.649%) y el crecimiento anual una media de 12.05% (mediana 11.89%, desviación estándar 3.38%). Estos estadísticos confirman que, aunque la tendencia de largo plazo es creciente, existen fluctuaciones mensuales relevantes que forman parte del ciclo crediticio.

Periodo_inicio	Periodo_fin	N_meses	Credito_inicio	Credito_fin	Crecimiento_acumulado_pct	CAGR_anual_pct	CAGR_mensual_pct	Crec_mensual_media_pct
2010-01-01	2025-08-01	187	139013.6055	739231.5127	431.769182	11.319301	0.897608	0.899641
Periodo_inicio	Periodo_fin	N_meses	Crec_mensual_mediana_pct	Crec_mensual_desv_std_pct	Crec_anual_media_pct	Crec_anual_mediana_pct	Crec_anual_desv_std_pct	
2010-01-01	2025-08-01	187	0.837881	0.643161	11.993945	11.907769	3.885928	

Ilustración 12 Resumen del crédito al sector privado (2010-01 a 2025-08)

Fuente: Elaboración propia con datos extraídos del API del BCH.

La segmentación por subperíodos evidencia cambios claros en el nivel del crédito y en el entorno monetario y macrofinanciero. El crédito promedio se ubica en L. 238,874.79 millones en el tramo Pre-COVID (2010–2019), aumenta a L. 415,219.03 millones durante COVID (2020–2021) y se eleva a L. 619,697.73 millones en Post-COVID (2022–2025).

Este escalamiento por etapas sugiere que el período posterior a la pandemia consolida un “nuevo nivel” nominal del saldo de crédito, consistente con la expansión observada en el acumulado 2010–2025. En la misma tabla, el crecimiento mensual promedio se mantiene alrededor de 0.88% en Pre-COVID, desciende a 0.63% en COVID y aumenta a 1.10% en Post-COVID, lo cual es coherente con una aceleración relativa en la fase posterior a la pandemia.

En cuanto al contexto monetario, La TPM promedio pasa de 5.87% en Pre-COVID a 3.44% en COVID y 3.73% en Post-COVID, reflejando una postura de política monetaria más baja en los tramos recientes respecto al ciclo previo.

Paralelamente, las tasas del sistema también se ajustan a la baja: la tasa activa promedio 19.07% en Pre-COVID, 16.41% en COVID y 15.62% en Post-COVID; la tasa pasiva promedio 3.66%, 2.93% y 2.44%, respectivamente. Por su parte, el entorno macroeconómico muestra cambios relevantes: la inflación interanual promedio 4.64% en Pre-COVID, 3.96% en COVID y 6.37% en Post-COVID, mientras que el tipo de cambio nominal de venta promedio 21.74, 24.44 y 24.98 L/USD en los tres subperíodos. Estas diferencias justifican reportar hallazgos descriptivos por tramos, dado que el contexto macrofinanciero no es homogéneo a lo largo de toda la muestra.

Adicionalmente, el análisis de valores atípicos (outliers) en las tasas de crecimiento del crédito identifica observaciones extremas que conviene documentar explícitamente para no ocultarlas en promedios agregados.

En Ilustración 13 se registran tres casos: (i) un crecimiento mensual alto en 2016-12 (4.19%), (ii) otro crecimiento mensual alto en 2021-11 (2.424%) y (iii) un crecimiento anual inusualmente bajo en 2021-04 (3.109%, incluso por debajo del límite inferior del rango IQR).

Estas observaciones no se eliminan en la etapa descriptiva: se reportan como parte del comportamiento efectivo de la serie, pues pueden corresponder a episodios reales del ciclo crediticio (aceleraciones puntuales, efectos base y normalización posterior), y se consideran más adelante cuando se discuta robustez y sensibilidad de resultados.




Ilustración 13 Observaciones atípicas en el crecimiento del crédito identificadas por el método IQR

Fuente: Elaboración propia con datos extraídos del API del BCH

4.3.1.3 RELACIÓN CON LOS OBJETIVOS

Los resultados descriptivos y estadísticos presentados en las subsecciones previas permiten vincular explícitamente los hallazgos con los objetivos e hipótesis del estudio, delimitando qué evidencia se establece en esta fase (diagnóstico empírico) y qué evidencia se contrasta en fases posteriores (evaluación de modelos predictivos).

En relación con el objetivo específico 1 (establecer variables macrofinancieras con correlación significativa con el crecimiento del crédito), el análisis por subperíodos confirma que la asociación entre el crecimiento mensual del crédito y sus determinantes no es estable en toda la muestra, sino que depende del régimen macroeconómico. En el tramo Pre-COVID (2010–2019) se identifican asociaciones de magnitud baja pero estadísticamente distinguibles en algunos casos (según correlaciones de Pearson/Spearman con intervalos de confianza bootstrap y ajuste por FDR), mientras que durante COVID (2020–2021) y Post-COVID (2022–2025) emergen relaciones más intensas y con cambios en el signo para ciertas variables. Esta evidencia se documenta en la tabla de correlaciones por período con intervalos de confianza bootstrap y

corrección por múltiples contrastes (Ilustración 14) y sustenta que la TPM, las tasas del sistema, la inflación y el tipo de cambio contienen información contemporánea o asociada al crecimiento del crédito, aunque con heterogeneidad temporal.

Periodo	X	Y	N	Pearson_r_CI95	Pearson_p_FDR	Spearman_r_CI95	Spearman_p_FDR
Pre-COVID (2010-2019)	tpm	crec_mensual_credito_pct	121	0.185 [-0.000, 0.377]	6.382e-02	0.202 [0.007, 0.385]	3.998e-02
Pre-COVID (2010-2019)	tasa_pasiva_mn	crec_mensual_credito_pct	121	-0.119 [-0.283, 0.046]	2.440e-01	-0.215 [-0.396, -0.009]	2.935e-02
COVID (2020-2021)	tpm	crec_mensual_credito_pct	22	-0.441 [-0.680, -0.158]	6.382e-02	-0.453 [-0.733, -0.079]	4.679e-02
COVID (2020-2021)	tasa_activa_mn	crec_mensual_credito_pct	22	-0.709 [-0.850, -0.407]	8.237e-04	-0.579 [-0.840, -0.175]	1.189e-02
COVID (2020-2021)	tasa_pasiva_mn	crec_mensual_credito_pct	22	-0.673 [-0.846, -0.370]	1.773e-03	-0.557 [-0.821, -0.114]	1.331e-02
COVID (2020-2021)	inflacion_ipc_interanual	crec_mensual_credito_pct	22	0.647 [0.378, 0.832]	2.854e-03	0.605 [0.206, 0.844]	8.607e-03
Post-COVID (2022-2025)	tpm	crec_mensual_credito_pct	44	-0.575 [-0.751, -0.332]	2.214e-04	-0.498 [-0.701, -0.237]	2.907e-03
Post-COVID (2022-2025)	tasa_activa_mn	crec_mensual_credito_pct	44	-0.713 [-0.841, -0.501]	8.234e-07	-0.628 [-0.796, -0.381]	7.534e-05
Post-COVID (2022-2025)	tasa_pasiva_mn	crec_mensual_credito_pct	44	-0.454 [-0.679, -0.141]	4.233e-03	-0.406 [-0.658, -0.076]	1.331e-02
Post-COVID (2022-2025)	inflacion_ipc_interanual	crec_mensual_credito_pct	44	0.445 [0.202, 0.633]	4.647e-03	0.511 [0.235, 0.712]	2.907e-03
Post-COVID (2022-2025)	tcn_venta	crec_mensual_credito_pct	44	-0.686 [-0.830, -0.390]	2.115e-06	-0.460 [-0.706, -0.136]	6.224e-03

Ilustración 14 Correlaciones entre el crecimiento mensual del crédito y determinantes macrofinancieros por subperíodo (coeficientes PEARSON y SPEARMAN, IC 95% por BOOTSTRAP y ajuste FDR)

Fuente: Elaboración propia con datos extraídos del API del BCH

Respecto al objetivo general (desarrollar un modelo predictivo robusto para el crédito bancario agregado), los resultados descriptivos muestran dos condiciones empíricas que justifican el enfoque metodológico del estudio: (i) una trayectoria de crecimiento de largo plazo del crédito y (ii) cambios relevantes en el entorno macrofinanciero entre subperíodos. En particular, el resumen de crecimiento (incluyendo crecimiento acumulado y/o medidas de ritmo de crecimiento) y el resumen por períodos (Ilustración 12 e Ilustración 15) evidencian que el proceso no es homogéneo en toda la muestra. Además, las pruebas formales de diferencias entre períodos confirman que variables clave del entorno (TPM, tasas del sistema, inflación y tipo de cambio) presentan cambios estadísticamente significativos entre tramos temporales (Ilustración 16). En conjunto, esta evidencia respalda la necesidad de evaluar enfoques predictivos que incorporen dinámica temporal y validación fuera de muestra, en línea con el diseño longitudinal de la investigación.

Periodo	N_obs	Credito_media	Credito_desv_std	TPM_media	TPM_desv_std	Crec_mensual_media_pct	Crec_mensual_desv_std_pct	Inflacion_media	TCN_media	Corr_TPM_vs_LogCredito	Corr_TPM_vs_CrecMensual
Pre-COVID (2010-2019)	122	241468.285218	78758.455991	0.058689	0.008632	0.876238	0.642681	4.640574	21.735480	0.117262	0.184702
COVID (2020-2021)	22	416868.221750	16149.877737	0.034432	0.006406	0.633856	0.696184	3.958182	24.436289	-0.602227	-0.440888
Post-COVID (2022-2025)	44	616953.637611	92455.578562	0.037330	0.011964	1.096892	0.567838	6.371591	24.977850	0.724616	-0.575163

Ilustración 15 Resumen descriptivo por subperiodos económicos (PRE-COVID, COVID, POST-COVID): niveles, dispersión y dinámica del crédito y variables macrofinancieras

Fuente: Elaboración propia con datos extraídos del API del BCH

Variable	Periodo_1	Periodo_2	N_1	N_2	Media_1	Media_2	Welch_t_p_FDR	Cohens_d	Levene_p_FDR	Delta_media	Sig_FDR
tpm	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	0.059	0.034	3.885e-17	2.908	6.403e-02	-0.024	Muy significativo
tpm	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	0.059	0.037	1.866e-15	2.221	9.081e-01	-0.021	Muy significativo
tasa_activa_mn	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	19.067	16.405	4.378e-21	2.503	3.598e-03	-2.661	Muy significativo
tasa_activa_mn	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	19.067	15.620	2.118e-19	2.758	1.999e-01	-3.447	Muy significativo
tasa_pasiva_mn	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	3.659	2.926	4.473e-09	1.831	9.632e-01	-0.733	Muy significativo
tasa_pasiva_mn	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	3.659	2.444	1.339e-64	3.477	1.614e-08	-1.214	Muy significativo
inflacion_ipc_interanual	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	4.641	3.958	1.652e-03	0.557	2.854e-02	-0.682	Muy significativo
inflacion_ipc_interanual	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	4.641	6.372	1.784e-05	-1.079	1.341e-03	1.731	Muy significativo
tcn_venta	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	21.735	24.436	9.813e-27	-1.425	3.259e-12	2.701	Muy significativo
tcn_venta	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	21.735	24.978	3.666e-34	-1.823	1.983e-19	3.242	Muy significativo
crec_mensual_credito_pct	Pre-COVID (2010-2019)	COVID (2020-2021)	121	22	0.876	0.634	1.460e-01	0.372	8.191e-01	-0.242	Nada significativo
crec_mensual_credito_pct	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	121	44	0.876	1.097	3.941e-02	-0.354	6.589e-01	0.221	Significativo
crec_anual_credito_pct	Pre-COVID (2010-2019)	COVID (2020-2021)	110	22	11.663	6.244	6.442e-10	2.081	9.632e-01	-5.419	Muy significativo
crec_anual_credito_pct	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	110	44	11.663	15.697	2.508e-10	-1.458	5.355e-01	4.034	Muy significativo
log_credito_sf_privado	Pre-COVID (2010-2019)	COVID (2020-2021)	122	22	12.341	12.940	5.232e-40	-1.970	8.098e-10	0.598	Muy significativo
log_credito_sf_privado	Pre-COVID (2010-2019)	Post-COVID (2022-2025)	122	44	12.341	13.321	4.918e-57	-3.343	3.922e-07	0.980	Muy significativo

Ilustración 16 Diferencias entre subperiodos en variables macroeconómicas y del crédito (WELCH T-TEST, MANN-WHITNEY, KOLMOGOROV-SMIRNOV Y LEVENS; tamaños de EFECTO; P ajustados por FDR)

Fuente: Elaboración propia con datos extraídos del API del BCH

En cuanto a las hipótesis, los resultados de correlación y de diferencias entre períodos aportan sustento empírico preliminar para la hipótesis específica 1 ($H_{1,1}$): si la TPM y determinantes macrofinancieros muestran asociación estadística con el crecimiento del crédito (y dicha asociación varía por régimen), entonces es razonable esperar que su incorporación aporte información incremental frente a enfoques puramente univariantes. Esta hipótesis se contrasta de manera directa en la fase de evaluación predictiva mediante la comparación fuera de muestra entre especificaciones univariantes y multivariantes (sección de modelos).

De manera análoga, la evidencia de heterogeneidad temporal, presencia de episodios atípicos y cambios de régimen documentados en el análisis descriptivo (4.3.1.2) proporciona motivación empírica para la hipótesis específica 2 ($H_{1,2}$): en un contexto donde las relaciones no son necesariamente lineales ni estables, es plausible que estrategias de modelación más flexibles o con mecanismos de regularización/dinámica temporal obtengan mejoras en desempeño predictivo. La verificación de esta hipótesis se realiza en la comparación formal de métricas fuera de muestra en las secciones correspondientes a resultados de modelado.

Finalmente, la hipótesis específica 3 ($H_{1,3}$) sobre interpretabilidad no se evalúa en esta etapa descriptiva, sino en la fase posterior de explicabilidad del modelo, donde se analizará la contribución relativa de los determinantes macrofinancieros mediante técnicas de interpretabilidad.

4.3.1.4 ANÁLISIS ESTADÍSTICO

Con el propósito de asegurar validez estadística antes de la modelación predictiva, se aplicó un conjunto de pruebas estándar para series temporales macrofinancieras: (i) estacionariedad (ADF y KPSS), (ii) normalidad y forma (asimetría, curtosis y pruebas formales), (iii) correlación cruzada con rezagos (CCF) y (iv) causalidad en sentido de Granger. Estas pruebas permiten caracterizar propiedades estocásticas de las series y fundamentar transformaciones y decisiones de especificación.

Previo a la estimación de modelos de pronóstico, se evaluó la presencia de raíz unitaria y estacionariedad mediante las pruebas Augmented Dickey–Fuller (ADF) y Kwiatkowski–Phillips–Schmidt–Shin (KPSS). En términos operativos, ADF contrasta como hipótesis nula la existencia de raíz unitaria (no estacionariedad), mientras que KPSS contrasta como hipótesis nula la estacionariedad. Los resultados consolidados por variable se presentan en la Ilustración 17.

En el crédito en nivel, ambas pruebas coinciden en no estacionariedad: ADF no rechaza raíz unitaria (estadístico 0.246; $p=0.975$) y KPSS rechaza estacionariedad (estadístico 0.416; $p=0.010$). Un patrón análogo se observa en TPM, tasa activa, inflación y tipo de cambio, que también aparecen como no estacionarias bajo ADF ($p>0.10$) y/o con rechazo de estacionariedad en KPSS ($p\approx 0.01-0.03$ en TPM, tasa activa, inflación y tcn_venta).

Esto es consistente con la presencia de componentes persistentes y/o tendencias en variables macrofinancieras en nivel.

Variable	ADF_estadistico	ADF_pvalue	ADF_conclusion	KPSS_estadistico	KPSS_pvalue	KPSS_conclusion
credito_sf_privado	0.246456	0.974750	No estacionaria	0.415933	0.010000	No estacionaria
tpm	-1.526458	0.520385	No estacionaria	0.213925	0.010778	No estacionaria
tasa_activa_mn	-1.386271	0.588840	No estacionaria	0.232477	0.010000	No estacionaria
tasa_pasiva_mn	-0.976546	0.761722	No estacionaria	0.120885	0.096509	Estacionaria
inflacion_ipc_interanual	-2.269284	0.182066	No estacionaria	0.166918	0.032569	No estacionaria
tcn_venta	-1.108628	0.711619	No estacionaria	0.422281	0.010000	No estacionaria
log_credito_sf_privado	-0.779660	0.825024	No estacionaria	0.138390	0.064093	Estacionaria
crec_mensual_credito_pct	-2.600933	0.092805	No estacionaria	0.069559	0.100000	Estacionaria
crec_anual_credito_pct	-2.795911	0.058860	No estacionaria	0.099842	0.100000	Estacionaria

Ilustración 17 Resultados de estacionariedad (ADF y KPSS)

Fuente: Elaboración propia con datos extraídos del API del BCH.

En contraste, varias transformaciones del crédito muestran un comportamiento más compatible con estacionariedad. El logaritmo del crédito mantiene p alto en ADF ($p=0.825$), pero en KPSS no se rechaza estacionariedad (estadístico 0.138; $p=0.064$), lo que sugiere que la transformación logarítmica reduce el componente tendencial y estabiliza parcialmente el proceso. De forma más clara, las tasas de crecimiento del crédito se aproximan a un comportamiento estacionario en KPSS: crecimiento mensual (KPSS $p=0.100$) y crecimiento anual (KPSS $p=0.100$). Aunque en ADF ambas series quedan cercanas al umbral ($p=0.093$ y $p=0.059$, respectivamente), el patrón conjunto ADF/KPSS respalda el uso de transformaciones (log y/o crecimientos) para reducir no estacionariedad y evitar riesgos de regresión espuria en el modelado.

Dado que las variables macrofinancieras suelen presentar asimetrías, colas pesadas y cambios de régimen, se complementó el análisis con medidas de forma y pruebas formales de normalidad: asimetría (skewness), curtosis (exceso), Shapiro–Wilk, Jarque–Bera y Anderson–Darling. Los resultados se reportan en la Ilustración 18.

Variable	N	Asimetria_skew	Curtosis_exceso	Shapiro_p	Decision_Shapiro	JarqueBera_p	Decision_JarqueBera	Anderson_A2	AD_crit_5pct	Decision_AD_5pct
credito_sf_privado	188	0.753922	-0.456547	1.979562e-09	Rechaza normalidad	6.433688e-05	Rechaza normalidad	4.960533	0.771	Rechaza normalidad
inflacion_ipc_interanual	188	1.320629	2.128932	3.702292e-10	Rechaza normalidad	1.725262e-19	Rechaza normalidad	5.259241	0.771	Rechaza normalidad
tasa_activa_mn	188	-0.405857	-0.803361	3.030355e-06	Rechaza normalidad	5.892705e-03	Rechaza normalidad	2.371889	0.771	Rechaza normalidad
tasa_pasiva_mn	188	-0.223896	-1.433706	2.679800e-10	Rechaza normalidad	1.576350e-04	Rechaza normalidad	6.926120	0.771	Rechaza normalidad
tcn_venta	188	-0.555611	-1.165230	1.177287e-11	Rechaza normalidad	4.164994e-05	Rechaza normalidad	9.711409	0.771	Rechaza normalidad
tpm	188	-0.284396	-1.185919	2.790942e-11	Rechaza normalidad	1.159866e-03	Rechaza normalidad	7.674592	0.771	Rechaza normalidad

Ilustración 18 Medidas de forma y pruebas de normalidad

Fuente: Elaboración propia con datos extraídos del API del BCH.

Los resultados muestran un rechazo sistemático de normalidad para las variables evaluadas. En todas las series, Shapiro–Wilk presenta p-values extremadamente pequeños (por ejemplo, crédito $p \approx 1.98e-09$; TPM $p \approx 2.79e-11$; TCN $p \approx 1.18e-11$) y Jarque–Bera también rechaza normalidad (por ejemplo, inflación $p \approx 1.73e-19$; TPM $p \approx 1.16e-03$).

Adicionalmente, Anderson–Darling supera ampliamente el crítico al 5% (A_2 entre ~ 2.37 y ~ 9.71 frente a crítico 0.771), confirmando desviaciones fuertes respecto al patrón gaussiano.

Las medidas de forma caracterizan la naturaleza de esas desviaciones: la inflación presenta asimetría positiva marcada ($skew=1.321$) y curtosis positiva ($exceso=2.129$), indicando colas pesadas y valores extremos hacia arriba; el crédito en nivel presenta asimetría positiva (0.754) consistente con una distribución sesgada por crecimiento nominal; mientras que TPM, tasa activa, tasa pasiva y TCN muestran asimetrías negativas moderadas (TCN $skew=-0.556$; TPM $skew=-0.284$) y curtosis de exceso negativa en varios casos (TPM $exceso=-1.186$), coherente con distribuciones no gaussianas y acotamientos institucionales o dinámicas de política.

Este diagnóstico justifica interpretar con cautela inferencias paramétricas basadas en normalidad y refuerza el uso de criterios robustos centrados en desempeño de pronóstico fuera de muestra, así como la documentación explícita de asimetrías/colas como rasgos empíricos del sistema macrofinanciero.

Para explorar la asociación temporal entre la postura monetaria y el crédito, se estimó la función de correlación cruzada (CCF) entre la TPM y el logaritmo del crédito, evaluando rezagos $k = 0-24$ (interpretados como “TPM adelantada k meses” respecto al crédito). Los coeficientes por rezago y el umbral de significancia aproximado al 95% se presentan en la **Ilustración 19**.

Los resultados muestran un patrón robusto: la correlación cruzada es negativa y estadísticamente significativa en todos los rezagos analizados ($|CCF| > 0.1429$). En particular, desde $k=0$ la CCF es -0.529 y se mantiene en torno a -0.53 a -0.62 conforme aumentan los rezagos, alcanzando magnitudes cercanas a -0.617 en el tramo $k \approx 21-22$ y manteniéndose alrededor de -0.615 hacia $k=24$. La estabilidad del signo y la magnitud sugiere que, en la muestra completa, aumentos de la TPM se asocian con menores niveles (o menor dinámica) del crédito en logaritmos,

consistente con un canal de transmisión donde un endurecimiento monetario coincide con desaceleración del crédito.

Rezag	CCF_TPM_to_LogCredito	Limite_95	Significativo_95	
0	0	-0.528606	0.142948	Si
1	1	-0.531181	0.142948	Si
2	2	-0.533997	0.142948	Si
3	3	-0.537187	0.142948	Si
4	4	-0.540497	0.142948	Si
5	5	-0.544022	0.142948	Si
6	6	-0.547666	0.142948	Si
7	7	-0.551517	0.142948	Si
8	8	-0.555373	0.142948	Si
9	9	-0.559521	0.142948	Si
10	10	-0.563734	0.142948	Si
11	11	-0.568270	0.142948	Si
12	12	-0.572962	0.142948	Si
13	13	-0.577876	0.142948	Si
14	14	-0.582823	0.142948	Si
15	15	-0.587908	0.142948	Si
16	16	-0.592917	0.142948	Si
17	17	-0.597940	0.142948	Si
18	18	-0.602941	0.142948	Si
19	19	-0.607931	0.142948	Si
20	20	-0.612924	0.142948	Si
21	21	-0.615040	0.142948	Si
22	22	-0.617056	0.142948	Si
23	23	-0.616055	0.142948	Si
24	24	-0.615015	0.142948	Si

Ilustración 19 CCF TPM - log(crédito) (k=0-24)

Fuente: Elaboración propia con datos extraídos del API del BCH.

Debe enfatizarse que la CCF describe co-movimiento temporal y no identifica causalidad estructural; su valor en esta etapa es evidenciar que la relación TPM–crédito no es contemporánea pura, sino que presenta asociación persistente a través de un amplio rango de rezagos, lo cual es pertinente para justificar la inclusión de rezagos en modelos dinámicos.

Finalmente, se aplicó la prueba de causalidad en sentido de Granger para evaluar si los rezagos de la TPM contienen información predictiva sobre el crédito más allá de la contenida en la historia del propio crédito. Los resultados se reportan en la Ilustración 20.

Rezago	TPM→Credito_F-stat	TPM→Credito_p-value	TPM→Credito_Significativo	Credito→TPM_F-stat	Credito→TPM_p-value	Credito→TPM_Significativo
1	0.627480	0.429301	No	0.187177	0.665783	No
2	0.562267	0.570908	No	0.669245	0.513358	No
3	0.855975	0.465129	No	0.934380	0.425300	No
4	1.065605	0.375099	No	0.987146	0.415989	No
5	1.680188	0.141806	No	0.808365	0.545144	No
6	1.696747	0.124585	No	0.671279	0.672987	No
7	1.810365	0.088321	*	0.687007	0.682940	No
8	1.704073	0.100971	No	0.603155	0.774315	No
9	1.549969	0.134801	No	1.025608	0.421884	No
10	1.663821	0.093740	*	0.947422	0.491733	No
11	1.985844	0.033229	**	1.121294	0.348265	No
12	2.301451	0.010106	**	1.032966	0.421742	No

Ilustración 20 Causalidad de GRANGER (TPM -> crédito)

Fuente: Elaboración propia con datos extraídos del API del BCH.

Los p-values indican que no hay evidencia de causalidad de Granger en horizontes cortos (por ejemplo, rezagos 1–6 con $p=0.429$ a $p=0.125$). Sin embargo, aparece evidencia marginal en el rezago 7 ($p=0.088$) y en el rezago 10 ($p=0.094$), y evidencia estadísticamente significativa a partir de rezagos más largos: 11 meses ($F=1.986$; $p=0.033$) y 12 meses ($F=2.301$; $p=0.010$). Este patrón es coherente con la idea de rezagos de transmisión: la TPM no aporta poder predictivo inmediato sobre el crédito, pero sí contiene información relevante en horizontes cercanos al año.

La combinación CCF + Granger sugiere una relación temporal consistente entre TPM y crédito, con asociación negativa persistente y con evidencia formal de contenido predictivo en rezagos largos. Estos hallazgos justifican metodológicamente el uso de rezagos de política monetaria en especificaciones econométricas y en el diseño de variables de entrada para modelos predictivos.

4.3.1.5 COSISTENCIA ECONÓMICA ENTRE TPM Y EL CREDITO

Los hallazgos anteriores permiten dialogar sobre el verdadero impacto que tiene el TPM en el crédito conforme a las teorías económicas, si lo vemos por tres dimensiones signos, estructura temporal y asimetría.

Si hablamos de los signos, la correlación negativa y persistente entre la TPM y el logaritmo del crédito ($r = -0.529$ contemporáneo, alcanzando -0.617 en rezagos cercanos al año, significativa en todos los rezagos $k = 0-24$) es plenamente consistente con la predicción del canal de tasas

(Mishkin, 2022) y del canal de préstamo bancario (Kashyap & Stein, 2000): un endurecimiento monetario coincide con menor dinamismo del crédito. Este resultado no es extraño en el contexto de economías emergentes, donde la literatura ha documentado transmisiones ambiguas (Mishra & Montiel, 2013); el caso hondureño confirma que el canal bancario sí cumple su función de transmisión.

Respecto a la estructura temporal, la causalidad de Granger no detecta poder predictivo en horizontes cortos ($k = 1-6$, $p > 0.10$), pero sí en horizontes largos: marginal en $k = 7$ y $k = 10$, y estadísticamente significativa en $k = 11$ ($p = 0.033$) y $k = 12$ ($p = 0.010$). Esta ventana de transmisión de aproximadamente un año es coherente con tres marcos teóricos: el acelerador financiero (Bernanke et al., 1998), donde la transmisión opera vía revaluación de colaterales y patrimonio empresarial; la información asimétrica (Stiglitz & Weiss, 1981), donde los bancos racionan crédito mediante endurecimiento de criterios de aprobación con desfase contractual; y el canal de préstamo bancario (Kashyap & Stein, 2000), donde el ajuste opera vía hojas de balance bancarias.

La asimetría entre la CCF en niveles y en diferencias merece atención teórica: mientras que en niveles la asociación es fuerte y persistente, al transformar a diferencias la significancia se concentra en $k = 0$ y $k = 2$. Esta divergencia refleja una relación de equilibrio de largo plazo más una dinámica de corto plazo selectiva, lo cual sugiere indicios de no linealidad y dependencia del régimen, consistente con las predicciones de (Mishra & Montiel, 2013) sobre transmisión asimétrica en economías emergentes.

En síntesis, la evidencia empírica es plenamente consistente con las cuatro teorías de sustento adoptadas, precisando que la transmisión existe con el signo correcto, opera con rezagos cercanos al año, presenta indicios de no linealidad, y se canaliza primordialmente vía costo de fondeo bancario más que por respuesta directa al instrumento de política. Estos hallazgos validan empíricamente la operatividad del canal bancario de transmisión monetaria en Honduras.

4.3.2 ANÁLISIS CUALITATIVO

Dado que la investigación no contempló instrumentos cualitativos primarios (entrevistas, grupos focales u observación directa), el análisis cualitativo se desarrolla mediante análisis

documental de fuentes oficiales del Banco Central de Honduras: (i) Memoria Anual 2024 y (ii) Informe de Estabilidad Financiera (IEF) diciembre 2024.

Estas fuentes se emplean para contextualizar los patrones cuantitativos ya reportados en 4.3.1 y para sustentar interpretaciones institucionales sobre transmisión monetaria, condiciones financieras y dinámica del crédito.

4.3.2.1 CATEGORÍAS O TEMAS EMERGENTES

Categoría 1: Normalización monetaria y transmisión con rezagos (postura TPM y proceso de desinflación).

La documentación institucional describe explícitamente un tránsito desde condiciones monetarias favorables hacia un sendero de normalización. El BCH señala que mantuvo la TPM en 3.00% hasta agosto de 2024 para favorecer condiciones financieras de recuperación tras la pandemia, y que luego inició el proceso de normalización con un aumento de 100 pb para ubicarla en 4.00% (Banco Central de Honduras, 2024b). Este encuadre cualitativo es congruente con el enfoque de rezagos de transmisión que motivó los análisis temporales (Granger/CCF) reportados en 4.3.1.4.

Categoría 2: Condiciones crediticias restrictivas y costo del financiamiento como freno a nuevo crédito.

El IEF vincula directamente el aumento de tasas con menor apetito por nuevo crédito: indica que “esta política de tasas encarece el endeudamiento existente y reduce el apetito por nuevo crédito”, y además asocia el incremento en tasas activas con presiones sobre riesgos de pago y calidad de cartera (Banco Central de Honduras, 2024a). En la misma línea, el IEF reporta que en 2024 la cartera crediticia bancaria creció a un ritmo más lento en un contexto de condiciones crediticias más restrictivas, con incrementos continuos en tasas activas y una normalización de la demanda (especialmente en los últimos seis meses del año) (Banco Central de Honduras, 2024a).

Categoría 3: Liquidez, fondeo y competencia por depósitos como canal financiero de transmisión.

El IEF destaca que en 2024 se observó un aumento marcado en tasas pasivas pagadas a inversionistas/prestamistas institucionales (IPP), asociado a renegociaciones y mayor competencia por captar/retener recursos, lo que incide en el costo de fondeo del sistema (Banco Central de Honduras, 2024a). Además, en su análisis de operaciones monetarias y mercado de dinero, el IEF relaciona la evolución de liquidez y costos de fondeo con cambios de política monetaria (incluyendo el ajuste de la TPM en agosto de 2024) (Banco Central de Honduras, 2024a). Esta categoría ayuda a interpretar por qué, incluso antes de observar efectos “reales” en crédito, pueden cambiar las tasas pasivas/activas y, con ello, el incentivo a ofertar crédito.

Categoría 4: Choques macro y estabilidad externa (inflación, tipo de cambio y motivación de política).

La Memoria Anual plantea explícitamente que la conducción de política buscó contener presiones inflacionarias de segunda vuelta y fortalecer la posición externa, mencionando medidas de liquidez y ajustes de instrumentos desde 2022–2023, y en 2024 el inicio del sendero de normalización para salvaguardar estabilidad externa y continuar la desinflación (Banco Central de Honduras, 2024b). Complementariamente, al discutir tipo de cambio efectivo real, la Memoria señala que la depreciación cambiaria “atenuó” el comportamiento del indicador, situando al tipo de cambio como parte del entorno macro que interactúa con inflación y competitividad (Banco Central de Honduras, 2024b). Esta categoría se alinea con la necesidad (ver EDA 4.1) de analizar el periodo completo con cortes, porque los choques (pandemia, inflación global, etc.) alteran el régimen macrofinanciero.

4.3.2.2 CITAS O EJEMPLOS

Dado que el diseño de esta investigación es macrofinanciero y se basa en series estadísticas oficiales, no se recolectaron testimonios de informantes primarios (entrevistas, grupos focales u observación participante). En su lugar, se incorporan citas documentales de publicaciones oficiales del BCH (IEF y Memoria Anual) como “ejemplos” que ilustran el contexto institucional de las categorías emergentes.

Ejemplo 1 - Liquidez y decisiones de política monetaria (canal de liquidez):

“Este comportamiento refleja la evolución de la intermediación financiera, influenciada por diversos factores, entre los que destacan (...) los cambios en las decisiones de política monetaria.” (Banco Central de Honduras, 2024a, p. 34)

Ejemplo 2 - Composición de fuentes de liquidez (preferencias por plazos y costos):

“La composición del fondeo refleja una preferencia por los mecanismos más eficientes en términos de plazos y costos, con un énfasis en el mercado interbancario.” (Banco Central de Honduras, 2024a, p. 34)

Ejemplo 3 - Ajustes de TPM en 2024 (normalización de postura):

“(...) ajustar la TPM en cien puntos básicos (100 pb), estableciéndola en (...) 4.00%, a partir del 5 de agosto de 2024.” (Banco Central de Honduras, 2024a, p. 34)

E Ejemplo 4 - Segundo ajuste de TPM en 2024 (continuación del endurecimiento):

“(...) un segundo incremento en la TPM de ciento setenta y cinco puntos básicos (175 pb), ubicándose en 5.75% (...), a partir de 28 de octubre de 2024.” (Banco Central de Honduras, 2024a, p. 34)

Ejemplo 5 - Competencia por depósitos y costo de fondeo (tasas pasivas/IPP):

“En 2024, la tasa (...) pagada a los IPP alcanzó 13.5% (...) Este ascenso obedece a la renegociación (...) [e] intensificado la competencia entre bancos...” (Banco Central de Honduras, 2024a, p. 68)

Ejemplo 6 - Normalización monetaria/cambiaria y posición externa (marco macro):

“(...) la solidez de las Reservas Internacionales Netas (RIN) se sustentó en (...) el proceso de normalización de la política monetaria y cambiaria...” (Banco Central de Honduras, 2024a, p. 13)

Ejemplo 7 - Instrumentos que referencian la TPM (vinculación institucional):

“(…) los saldos de las cuentas de inversiones obligatorias de registro contable en MN registradas en el BCH y pertenecientes a las instituciones del sistema financiero, devengarán un rendimiento anual equivalente al 50% de la TPM vigente” (Banco Central de Honduras, 2024b, p. 6)

4.3.2.3 INTERPRETACIÓN

La evidencia documental del BCH sobre normalización monetaria y endurecimiento de condiciones financieras puede interpretarse a la luz de los resultados cuantitativos de dependencia temporal y rupturas por subperíodos. En primer lugar, la relación política monetaria - crédito no aparece como inmediata: la causalidad de Granger en el sentido TPM - crédito no muestra evidencia en horizontes cortos (rezagos 1 - 6 con p-values entre 0.429 y 0.125), pero sí emerge en horizontes más largos, con significancia estadística en 11 meses ($p=0.033$) y 12 meses ($p=0.010$), además de evidencia marginal en 7 y 10 meses ($p=0.088$ y $p=0.094$). Este patrón es consistente con un mecanismo de transmisión con rezagos extendidos, donde los cambios en la postura monetaria afectan al crédito con desfases cercanos al año.

En segundo lugar, la correlación cruzada entre la TPM adelantada k meses y el logaritmo del crédito es negativa y estadísticamente significativa en todo el rango evaluado ($k = 0..24$), con magnitudes aproximadas entre -0.53 y -0.62 (límite 95% ≈ 0.143). Este patrón de co-movimiento persistente es compatible con un canal de tasas en el que una postura monetaria más restrictiva tiende a coincidir con una menor dinámica del crédito: el IEF documenta que en 2024 la TPM fue ajustada al alza (100 pb en agosto y posteriormente un segundo incremento en octubre) como parte de las decisiones de política monetaria (Banco Central de Honduras, 2024a). A la vez, el informe describe un entorno financiero donde el costo de fondeo (vía tasas pasivas) se incrementa por competencia por captar/retener depósitos, lo cual constituye un mecanismo adicional por el que cambios en la postura monetaria y condiciones de liquidez pueden transmitirse al crédito (Banco Central de Honduras, 2024a). No obstante, la CCF describe asociación dinámica y no identifica causalidad estructural; por ello, se interpreta como evidencia descriptiva que complementa (pero no sustituye) los contrastes formales.

Finalmente, los contrastes por subperíodos respaldan la interpretación de cambios de régimen macrofinanciero. Las pruebas de diferencias por período muestran variaciones

estadísticamente significativas en la TPM y en las tasas del sistema entre el tramo Pre-COVID y los tramos COVID/Post-COVID (p-values extremadamente pequeños), así como cambios relevantes en inflación y tipo de cambio entre períodos; además, el crecimiento del crédito presenta cambios detectables entre subperíodos (por ejemplo, diferencias significativas en crecimiento mensual entre Pre-COVID y Post-COVID). Estos resultados son coherentes con la narrativa institucional de un entorno no homogéneo: la Memoria Anual reporta que en 2024 se observaron resultados macroeconómicos favorables (incluyendo inflación baja y fortalecimiento de la posición externa) y atribuye parte de ello a la implementación de medidas de política monetaria y cambiaria orientadas a mantener la estabilidad de precios y fortalecer la posición externa (Banco Central de Honduras, 2024b). En conjunto, la evidencia sugiere que la dinámica del crédito debe interpretarse dentro de un marco con cambios de postura monetaria, condiciones de fondeo y shocks macro, que reconfiguran en el tiempo la relación entre tasas, inflación y expansión crediticia (Banco Central de Honduras, 2024a).

4.3.2.4 TRIANGULACIÓN

La triangulación se realiza contrastando (i) la evidencia documental oficial del Banco Central de Honduras (BCH), contenida en la Memoria Anual 2024 y el Informe de Estabilidad Financiera (IEF) diciembre 2024, con (ii) la evidencia cuantitativa producida en la investigación (pruebas de Granger, CCF y contrastes por subperíodos reportados en 4.3.1.4 y tablas asociadas). Cuando se mencionan resultados numéricos (p-values, CCF, etc.), estos provienen de las tablas estadísticas elaboradas en la tesis (no de los documentos BCH) y se usan aquí únicamente como “segunda evidencia”.

En primer lugar, existe convergencia en torno al cambio de postura monetaria y el inicio del sendero de normalización. La Memoria Anual 2024 documenta que el BCH mantuvo la TPM en 3.00% hasta agosto de 2024 y que, posteriormente, inició el proceso de normalización mediante un incremento de 100 pb que ubicó la TPM en 4.00%, enmarcando la decisión en la contención de choques y la continuidad del proceso de desinflación y la estabilidad externa (Banco Central de Honduras, 2024b).

Esta secuencia es consistente con la evidencia cuantitativa de la tesis, que identifica patrones temporales compatibles con transmisión monetaria con rezagos (según los contrastes temporales reportados en 4.3.1.4).

En segundo lugar, la triangulación también converge en que el canal monetario opera mediante condiciones de liquidez/fondeo y costos de financiamiento. El IEF describe que la evolución de la intermediación y la liquidez en 2024 estuvo influida por, entre otros factores, las decisiones de política monetaria, e incluye explícitamente los incrementos de la TPM (agosto y octubre de 2024) como parte del contexto de ese comportamiento (Banco Central de Honduras, 2024a, 2024b). Esta lectura institucional es coherente con los resultados cuantitativos por subperíodos (pruebas de diferencias por período), donde se observan cambios estadísticamente relevantes en variables de tasas y condiciones financieras entre etapas del ciclo.

La principal divergencia no es de dirección, sino de temporalidad: la Memoria y el IEF describen el marco de decisiones y sus mecanismos (normalización, instrumentos, liquidez), mientras que la evidencia cuantitativa de la tesis sugiere que la relación TPM-crédito no debe interpretarse como estrictamente contemporánea, sino como un proceso con rezagos (según los resultados de Granger/CCF reportados en 4.3.1.4).

Por tanto, la evidencia documental sustenta la lógica económica y la evidencia cuantitativa aporta el matiz de “cuándo” se manifiesta el contenido predictivo en el tiempo, dentro de la muestra analizada.

En conjunto, la triangulación fortalece la interpretación macrofinanciera porque los hallazgos estadísticos no quedan como un patrón aislado: se insertan en un marco institucional donde (a) se documenta la transición desde condiciones favorables hacia normalización de la política monetaria y (b) se reconoce que la dinámica financiera de corto plazo (liquidez/fondeo) está vinculada con cambios de política monetaria, incluyendo los ajustes de TPM de 2024 (Banco Central de Honduras, 2024a, 2024b).

En términos de rigor, esto justifica presentar resultados por subperíodos y utilizar herramientas temporales (rezagos) para describir la interacción entre política monetaria y crédito, evitando interpretaciones lineales inmediatas cuando el propio contexto institucional describe

procesos graduales y condicionados por choques (pandemia, inflación global y otros) y por el manejo de instrumentos.

En conclusión integrada es que el comportamiento del crédito debe analizarse dentro de un entorno macrofinanciero no homogéneo, donde la postura monetaria y las condiciones de fondeo evolucionan por fases y sus efectos se materializan con rezagos, en coherencia con el marco institucional reportado por el BCH (Banco Central de Honduras, 2024a, 2024b).

4.4 ANÁLISIS INFERENCIAL Y MODELOS APLICADOS

4.4.1 ANÁLISIS INFERENCIAL

El análisis inferencial se orienta a contrastar relaciones estadísticas entre variables macrofinancieras y el crédito, así como a evaluar cambios de régimen entre subperíodos. Dado que varias series en nivel exhiben alta persistencia y no estacionariedad (véase 4.3.1.4), las correlaciones en niveles se interpretan como asociaciones descriptivas (co-movimientos) y no como evidencia causal. Por ello, el análisis se complementa con: (i) correlaciones sobre la dinámica del crédito (crecimiento mensual) y por subperíodo, (ii) pruebas de diferencias entre períodos y (iii) contrastes temporales de precedencia predictiva (Granger/CCF presentados en 4.3.1.4).

La matriz de correlación en niveles muestra asociaciones consistentes con un canal de condiciones financieras: el logaritmo del crédito se asocia negativamente con la TPM ($r = -0.529$), con la tasa activa ($r = -0.693$) y con la tasa pasiva ($r = -0.911$). En paralelo, se observa una asociación positiva elevada entre el logaritmo del crédito y el tipo de cambio nominal de venta ($r = 0.945$). Sin embargo, estas magnitudes deben interpretarse con cautela: en presencia de tendencias comunes y alta persistencia en nivel, parte de la correlación puede reflejar co-movimiento de largo plazo y no una relación estructural contemporánea. En consecuencia, el análisis inferencial evita conclusiones causales basadas únicamente en correlación en niveles y contrasta los resultados con evidencia por subperíodos y sobre variables en tasas de variación.

Para capturar relaciones más cercanas a la dinámica de corto plazo, se analiza la correlación entre el crecimiento mensual del crédito y determinantes macrofinancieros. La matriz de correlación sobre crecimiento muestra asociaciones contemporáneas de menor magnitud: el

crecimiento mensual del crédito presenta una relación cercana a cero con la TPM ($r = -0.077$), negativa con la tasa activa ($r = -0.242$) y positiva moderada con la inflación interanual ($r = 0.260$). Este resultado sugiere que, a diferencia del co-movimiento en niveles, la relación contemporánea con el crecimiento del crédito es más débil y potencialmente más sensible al régimen macrofinanciero vigente. Por ello, el estudio complementa este diagnóstico con correlaciones por subperíodo con intervalos de confianza (Ilustración 15) permitiendo evaluar cambios en signo y magnitud entre Pre-COVID, COVID y Post-COVID.

Para contrastar formalmente si el proceso macrofinanciero es estable en el tiempo, se aplican pruebas de diferencias entre subperíodos (Welch-t para medias bajo varianzas desiguales, Mann-Whitney como contraste no paramétrico, Kolmogorov-Smirnov para diferencias distributivas y Levene para homogeneidad de varianzas), incluyendo tamaños de efecto y corrección por múltiples comparaciones (FDR). Los resultados (**Ilustración 16**) evidencian cambios estadísticamente significativos entre Pre-COVID y los tramos COVID/Post-COVID en variables clave de condiciones financieras y entorno macro (TPM, tasas del sistema, inflación y tipo de cambio). En conjunto, esto respalda que la inferencia debe reportarse con cortes temporales, ya que el período 2010–2025 no constituye un régimen homogéneo.

Con el fin de reforzar esta cautela interpretativa, se incorporó además un contraste formal de cointegración entre el logaritmo del crédito y la Tasa de Política Monetaria mediante la prueba de Engle–Granger. Este procedimiento permite evaluar si ambas series comparten una relación de equilibrio de largo plazo o si, por el contrario, su asociación en niveles responde principalmente a la presencia de tendencias persistentes. Desde el punto de vista metodológico, este paso resulta importante porque evita atribuir contenido estructural a correlaciones elevadas cuando las series exhiben no estacionariedad y co-movimientos de tendencia.

Par	EG_t_stat	EG_pvalue	crit_1pct	crit_5pct	crit_10pct	Conclusion_5pct
log_credito ~ tpm	-1.075402	0.887588	-3.955965	-3.368999	-3.067208	No cointegradas

Ilustración 21 Resultados de la prueba de cointegración de ENGLE–GRANGER entre logaritmo del crédito y TPM

Fuente: Elaboración propia con datos extraídos del API del BCH.

Los resultados muestran que no existe evidencia suficiente para afirmar cointegración entre ambas variables al nivel de significancia del 5%. En consecuencia, la asociación observada entre crédito y TPM en niveles no puede interpretarse como una relación estable de equilibrio de largo plazo, sino más bien como un co-movimiento que podría estar influido por persistencia, tendencias comunes y cambios de régimen a lo largo de la muestra. Este hallazgo refuerza la decisión de no derivar inferencias causales a partir de correlaciones contemporáneas en niveles y justifica complementar el análisis con evidencia sobre tasas de variación, segmentación temporal y modelos dinámicos de pronóstico.

4.4.2 MODELOS APLICADOS

En esta investigación se aplicaron dos familias de modelos para el pronóstico del crédito al sector privado en Honduras: por un lado, modelos econométricos tradicionales de series de tiempo; por otro, modelos de aprendizaje automático construidos sobre un esquema supervisado con rezagos del propio crédito y de variables macrofinancieras relevantes. El objetivo no fue únicamente identificar el modelo con menor error, sino evaluar si la incorporación de variables exógenas, la actualización dinámica de parámetros y la comparación bajo un protocolo simétrico de validación temporal modificaban de manera sustantiva el desempeño predictivo. En consecuencia, la evidencia se organizó en tres niveles: modelos econométricos estimados en forma estática y adaptativa, modelos de machine learning inicialmente evaluados bajo entrenamiento estático, y una comparación final bajo validación walk-forward, que constituye el criterio metodológicamente más exigente y comparable entre paradigmas.

En el bloque econométrico se estimaron un ARIMA univariado como benchmark, un SARIMAX con variables exógenas en versión estática, un SARIMAX con actualización walk-forward y, a nivel multivariado, un VECM condicionado por la evidencia de cointegración detectada en el sistema ampliado. Los resultados muestran que el mejor desempeño econométrico no provino del modelo más simple ni del más cargado de estructura, sino del SARIMAX con reestimación walk-forward, que alcanzó un RMSE en nivel de 3,724.16, un MAE de 2,862.65, un R^2 ajustado de 0.9946 y un MAPE de 0.44%. En contraste, el SARIMAX estático presentó un RMSE de 56,072.61 y el ARIMA univariado un RMSE de 65,291.23, mientras que el VECM

multivariado obtuvo un desempeño intermedio con RMSE de 19,581.79 y MAPE de 3.43%. En términos sustantivos, esto indica que la principal ganancia predictiva dentro del bloque econométrico no estuvo asociada únicamente a incorporar exógenas, sino a permitir que el modelo se actualizara conforme avanzaba la muestra, capturando con mayor precisión la inestabilidad del período post-COVID.

modelo	N_test	k_predictores	RMSE_log	MAE_log	R2_log	Adj_R2_log	RMSE_nivel	MAE_nivel	R2_nivel	Adj_R2_nivel	MAPE
ARIMA_univariado_estatico	37	0	0.100411	0.092096	0.322488	0.322488	65291.230403	58720.873328	0.270611	0.270611	8.724450
SARIMAX_exogenas_estatico	37	5	0.088098	0.080252	0.478465	0.394347	56072.608956	50637.660587	0.462039	0.375271	7.650241
SARIMAX_exogenas_walkforward	37	20	0.005688	0.004424	0.997826	0.995108	3724.158064	2862.652926	0.997627	0.994661	0.442522
SARIMAX_estacional_rezagos_estatico	37	5	0.257441	0.230450	-3.453563	-4.171880	153916.303892	135865.744875	-3.053394	-3.707167	20.046670
VECM_multivariado	37	5	0.038453	0.034988	0.900639	0.884613	24787.145381	22366.138129	0.894876	0.877920	3.426258

Ilustración 22 Desempeño de los modelos econométricos aplicados

Fuente: Elaboración propia con datos extraídos del API del BCH.

En el bloque de machine learning se entrenaron modelos lineales regularizados y no regularizados, así como algoritmos no lineales de mayor complejidad. Bajo el esquema estático del análisis, los mejores resultados correspondieron a LinearRegression y Ridge, con RMSE en nivel de 5,809.91 y 6,373.69, respectivamente, mientras que Lasso obtuvo un RMSE de 9,663.78. En cambio, los modelos de mayor complejidad —particularmente XGBoost, GradientBoosting, RandomForest y MLP— registraron errores considerablemente más altos y coeficientes de determinación negativos en varios casos, lo que evidencia una débil capacidad de generalización bajo ese protocolo. Sin embargo, dado que esta primera comparación no era estrictamente simétrica frente al SARIMAX walk-forward, dichos resultados debían interpretarse como una evaluación preliminar y no como una conclusión definitiva sobre la superioridad de un paradigma sobre otro.

modelo	RMSE_nivel	MAE_nivel	R2_nivel	MAPE
LinearRegression	5,536.86	4,334.80	0.9948	0.6644
Ridge	6,066.39	4,918.58	0.9937	0.7562
Lasso	9,182.98	8,754.27	0.9856	1.3863
XGBoost	166,290.50	147,017.10	-3.7134	21.7082
GradientBoosting	203,726.50	176,159.60	-6.1014	25.8726
RandomForest	205,851.70	178,954.70	-6.2503	26.3255
MLP	182,454,900,000.00	44,120,120,000.00	-6,595,875,000,000.0000	5,967,379.0000

Ilustración 23 Desempeño de los modelos de ML

Fuente: Elaboración propia con datos extraídos del API del BCH.

La comparación metodológicamente más relevante se obtuvo en el análisis, donde tanto el mejor modelo econométrico como los modelos de machine learning fueron sometidos al mismo protocolo de evaluación: walk-forward validation con ventana expansiva y predicción a un paso adelante. Bajo este criterio comparable, el mejor modelo de machine learning fue Lasso walk-forward, con RMSE en nivel de 3,503.77, MAE de 2,864.68, R^2 de 0.9979, R^2 ajustado de 0.9976 y MAPE de 0.45%. El SARIMAX walk-forward quedó muy cercano, con RMSE de 3,724.16, MAE de 2,862.65, R^2 de 0.9976, R^2 ajustado de 0.9968 y MAPE de 0.44%.


Esta evidencia obliga a matizar cualquier conclusión tajante: no se observa una brecha drástica entre ambos enfoques cuando se comparan bajo el mismo diseño temporal; más bien, se aprecia una competencia estrecha entre un modelo econométrico adaptativo y un modelo lineal regularizado parsimonioso.

En cambio, la ventaja de Lasso frente a los modelos estáticos sí resulta clara, tanto respecto al ARIMA como al SARIMAX sin reestimación.

Adicionalmente, se generaron las proyecciones fuera de muestra para el último cuatrimestre de 2025 utilizando los dos modelos con mejor desempeño empírico: Lasso walk-forward y SARIMAX walk-forward. Los resultados proyectados sugieren una trayectoria de crecimiento nominal sostenido para el cierre del ejercicio, con estimaciones que sitúan el saldo del crédito en un rango entre los L 743,489.69 millones (septiembre) y los L 758,580.41 millones (diciembre).

Esta expansión proyectada de entre 2.26% y 2.62% para el cierre de 2025 ratifica la fuerte inercia del crédito hondureño y valida de forma prospectiva la capacidad de los modelos para capturar su tendencia.

modelo	RMSE_log	MAE_log	RMSE_nivel	MAE_nivel	MAPE_nivel_pct	R2_nivel	p_efectivo	R2_adj_nivel
ML_Lasso_walkforward	0.005650	0.004551	3503.772620	2864.683854	0.454129	0.997900	4.0	0.997637
SARIMAX_walkforward	0.005688	0.004424	3724.158064	2862.652926	0.442522	0.997627	9.0	0.996836
SARIMAX_estatico	0.088098	0.080252	56072.608956	50637.660587	7.650241	0.462039	9.0	0.282718
ARIMA_estatico	0.100411	0.092096	65291.230403	58720.873328	8.724450	0.270611	NaN	NaN



Fecha	SARIMAX log	SARIMAX millones HNL	Lasso log	Lasso millones HNL	Crec. SARIMAX (%)	Crec. Lasso (%)
2025-09-01	13.519930	744099.461840	13.519110	743489.688435	0.658515	0.576027
2025-10-01	13.524435	747459.332633	13.524826	747751.263854	1.113023	1.152515
2025-11-01	13.531278	752591.549205	13.530326	751875.561658	1.807287	1.710432
2025-12-01	13.539204	758580.409645	13.535763	755974.428297	2.617434	2.264908




Ilustración 24 Métricas comparativas entre ambos tipos de modelos, gráfico comparativo en la prueba de ambos modelos con walk-forward y pronóstico

Fuente: Elaboración propia con datos extraídos del API del BCH.

Finalmente, la evidencia de comparación formal entre pronósticos confirma que la mejora de Lasso walk-forward sobre los modelos estáticos es estadísticamente significativa, mientras que frente a SARIMAX walk-forward la diferencia no resulta concluyente. En efecto, la prueba de Diebold-Mariano robusta con corrección HAC muestra que frente a SARIMAX estático la comparación favorece a Lasso walk-forward con $p = 0.000031$, y frente a ARIMA estático también favorece a Lasso walk-forward con $p = 0.000060$. No obstante, en la comparación justa entre

SARIMAX walk-forward y Lasso walk-forward, el estadístico robusto no rechaza igualdad de desempeño ($p = 0.629107$), lo que sugiere que ambos modelos poseen capacidades predictivas estadísticamente comparables dentro de la muestra de evaluación. Por tanto, el hallazgo central de esta sección no es que un paradigma “aniquile” al otro, sino que la actualización dinámica y la parsimonia del modelo son elementos más determinantes que la etiqueta econometría versus machine learning.

modelo_1	modelo_2	tipo_comparacion	DM_classico_stat	DM_classico_p	DM_HAC_t	DM_HAC_p	favorece_a	Dif. pérdida prom. (millones)
SARIMAX_walkforward	ML_Lasso_walkforward	justa_walkforward_vs_walkforward	0.5566	0.57781344	0.4830	0.62910673	ML_Lasso_walkforward	1.59
SARIMAX_estatico	ML_Lasso_walkforward	no_simetrica_estatico_vs_walkforward	8.5582	0.00000000	4.1679	0.00003074	ML_Lasso_walkforward	3,131.86
ARIMA_estatico	ML_Lasso_walkforward	no_simetrica_estatico_vs_walkforward	8.4543	0.00000000	4.0141	0.00005968	ML_Lasso_walkforward	4,250.67

Ilustración 25 Resultado de la prueba de DIEBOLD-MARIANO robusta

Fuente: Elaboración propia con datos extraídos del API del BCH

4.4.3 DISCUSIÓN DE HALLAZGOS

Los resultados obtenidos muestran que la dinámica del crédito al sector privado en Honduras responde a una combinación de alta persistencia autorregresiva, condiciones macrofinancieras cambiantes y rupturas de régimen que limitan la validez de enfoques estáticos. En primer lugar, la evidencia inferencial indica que las relaciones contemporáneas en niveles entre crédito, TPM, tasas del sistema y tipo de cambio deben interpretarse con cautela, dado que varias series presentan alta persistencia y no estacionariedad. En ese contexto, la asociación negativa observada entre el crédito y las tasas de interés es coherente con la teoría del canal de tasas, pero no basta por sí sola para sostener una lectura causal. Más bien, los resultados sugieren que el vínculo entre política monetaria y crédito en Honduras opera de forma indirecta, rezagada y sensible al régimen macroeconómico.

Desde la perspectiva de modelización, la comparación entre enfoques econométricos y de machine learning deja un resultado más matizado que la simple afirmación de que “un paradigma supera al otro”. Bajo evaluación estática, el modelo SARIMAX con exógenas mejoras frente al benchmark ARIMA al incorporar información macrofinanciera relevante, mientras que los modelos lineales regularizados de machine learning muestran un desempeño notablemente alto al explotar la estructura de rezagos del propio crédito y de las variables exógenas. Sin embargo, el hallazgo central aparece al imponer una comparación metodológicamente simétrica mediante

walk-forward validation: en ese escenario, Lasso walk-forward obtiene el menor RMSE en nivel, pero su ventaja frente a SARIMAX walk-forward es reducida y no resulta concluyente desde el punto de vista estadístico cuando se consideran contrastes robustos de igualdad predictiva. Esto implica que la diferencia relevante no está tanto en la etiqueta “económico” o “machine learning”, sino en la capacidad adaptativa del esquema de actualización frente a un entorno con cambios de régimen.

Este resultado dialoga con la literatura de pronóstico macroeconómico y financiero en economías con muestras relativamente pequeñas. En contextos como el hondureño, donde el número de observaciones es limitado y los shocks extraordinarios alteran los patrones históricos, los modelos más complejos no necesariamente generan mejores predicciones. De hecho, en esta investigación los modelos no lineales de mayor complejidad (como MLP y algunos ensambles) exhiben desempeños claramente inferiores, mientras que los enfoques parsimoniosos y regularizados conservan mejor la capacidad de generalización. Esto es consistente con la idea de que, bajo restricciones de muestra y presencia de inestabilidad estructural, la parsimonia suele ofrecer una mejor relación entre ajuste y robustez predictiva.

Otro hallazgo importante es que la inercia del propio crédito sigue siendo el principal determinante de su trayectoria de corto plazo. Esto coincide con la evidencia de interpretabilidad obtenida en el análisis del modelo Lasso, donde los rezagos del crédito concentran la mayor parte de la capacidad explicativa, relegando a las variables monetarias contemporáneas a un papel complementario. Lejos de invalidar la relevancia de la política monetaria, este resultado sugiere que su transmisión hacia el crédito no es inmediata, sino que se canaliza a través de rezagos, condiciones financieras intermedias y expectativas. En términos sustantivos, el crédito bancario hondureño parece comportarse como una variable de fuerte persistencia, en la que los choques de política no desplazan instantáneamente la trayectoria observada.

En conjunto, los hallazgos de esta investigación aportan tres contribuciones principales. Primero, muestran que la relación entre política monetaria y crédito en Honduras no puede analizarse adecuadamente sin considerar persistencia, no estacionariedad y cambio estructural. Segundo, evidencian que una comparación justa entre econometría y machine learning exige utilizar el mismo protocolo temporal de evaluación, ya que los resultados cambian de forma

importante cuando ambos enfoques se someten a validación walk-forward. Tercero, demuestran que en este contexto los modelos más útiles no son necesariamente los más sofisticados, sino aquellos que combinan parsimonia, capacidad de actualización y robustez frente a cambios de régimen.

En términos de cumplimiento de objetivos, los hallazgos permiten afirmar que la investigación sí desarrolló y validó un modelo de machine learning apto para el pronóstico del crédito bancario agregado hondureño en el horizonte 2010–2025, alcanzando niveles de ajuste fuera de muestra compatibles con la meta planteada. Asimismo, se cumplió el objetivo de comparar formalmente modelos econométricos y de machine learning bajo validación temporal, identificándose que un modelo lineal regularizado como Lasso puede ofrecer el menor error predictivo bajo esquema walk-forward, aunque con una ventaja acotada frente a SARIMAX walk-forward. En consecuencia, la evidencia respalda parcialmente la hipótesis alternativa general y las hipótesis específicas 1 y 2: la incorporación de variables macrofinancieras sí agrega valor frente al benchmark univariante, y al menos un modelo de machine learning logra reducir el error de pronóstico fuera de muestra respecto de los modelos econométricos de referencia; sin embargo, esa superioridad no debe interpretarse como absoluta ni universal, sino condicionada por la estructura temporal de evaluación, el tamaño muestral y la presencia de cambios de régimen. Del mismo modo, la hipótesis específica 3 encuentra sustento en el análisis de interpretabilidad, ya que las técnicas aplicadas permiten jerarquizar la contribución de los predictores y traducir el resultado técnico en una lectura económica más trazable.

4.4.4 LIMITACIONES

A pesar de la consistencia metodológica alcanzada en la comparación entre modelos econométricos y de machine learning, el estudio presenta limitaciones que deben reconocerse explícitamente para interpretar sus resultados con prudencia. En primer lugar, la base empírica trabaja con una frecuencia mensual y con un tamaño muestral relativamente acotado para estándares de aprendizaje automático, lo que restringe la capacidad de modelos más complejos

para generalizar sin sobreajuste. Esta limitación se hizo evidente en el desempeño de algoritmos no lineales como Random Forest, XGBoost y MLP, cuyos resultados fueron inferiores a los obtenidos por modelos lineales regularizados y por el SARIMAX bajo ciertos esquemas de validación.

En segundo término, aunque se procuró una comparación más justa mediante validación temporal walk-forward, la capacidad predictiva observada sigue condicionada por el período histórico analizado y, especialmente, por la presencia de rupturas estructurales asociadas al choque pandémico y a la fase posterior de normalización macrofinanciera. En este sentido, los resultados no deben interpretarse como relaciones invariantes en el tiempo, sino como evidencia dependiente de un contexto macroeconómico específico en el que la volatilidad, los cambios regulatorios y las respuestas de política pudieron alterar la dinámica habitual del crédito.

Una tercera limitación radica en la naturaleza de las variables disponibles. Aunque se incorporaron determinantes macrofinancieros relevantes como la TPM, tasas del sistema, inflación y tipo de cambio, el modelo no incluye otras variables potencialmente explicativas del crédito, tales como indicadores de actividad económica más desagregados, empleo, cartera en mora, expectativas de agentes o medidas microprudenciales. Por ello, parte de la dinámica del crédito podría estar siendo capturada indirectamente por la propia inercia de la serie y no exclusivamente por los canales contemporáneos de política monetaria.

Asimismo, debe señalarse que la interpretabilidad del mejor modelo de machine learning no elimina por sí sola problemas clásicos de inferencia económica. Aunque SHAP y los coeficientes regularizados permiten identificar la importancia relativa de los predictores, estos resultados no constituyen prueba definitiva de causalidad estructural. En particular, persiste la posibilidad de endogeneidad, causalidad bidireccional y simultaneidad entre crédito y variables de política, por lo que los hallazgos deben entenderse principalmente en clave predictiva y no como estimaciones causales fuertes.

Finalmente, las proyecciones fuera de muestra elaboradas para el cierre de 2025 descansan sobre supuestos simplificadores respecto al comportamiento futuro de las variables exógenas. Tales ejercicios son útiles como referencia técnica y de planeación, pero no sustituyen escenarios prospectivos más amplios ni análisis de sensibilidad ante trayectorias alternativas de política

monetaria, inflación o tipo de cambio. En consecuencia, las proyecciones deben interpretarse como trayectorias condicionales al marco de información disponible y no como valores puntuales definitivos.

4.5 SÍNTESIS DE HALLAZGOS

4.5.1 PRINCIPALES HALLAZGOS

Los resultados obtenidos permiten identificar cinco hallazgos centrales. En primer lugar, se confirma que la incorporación de información macrofinanciera mejora la capacidad predictiva respecto a un enfoque estrictamente univariante. En la comparación econométrica, el modelo ARIMA constituyó un benchmark útil, pero fue superado por especificaciones que integran variables exógenas, especialmente por SARIMAX bajo un esquema de validación walk-forward. Este resultado respalda la hipótesis de que la Tasa de Política Monetaria, las tasas del sistema bancario, la inflación y el tipo de cambio contienen información incremental relevante para anticipar la evolución del crédito agregado al sector privado.

En segundo lugar, la comparación justa entre paradigmas, realizada bajo la misma arquitectura temporal de evaluación, mostró que el desempeño predictivo no depende únicamente de que un modelo pertenezca a la familia econométrica o a la de machine learning, sino de su adecuación a la estructura de los datos. Bajo el esquema walk-forward, el mejor modelo de machine learning se mantuvo competitivo y con elevada capacidad explicativa, pero el modelo SARIMAX walk-forward registró el menor error fuera de muestra en la comparación final. En consecuencia, no se verifica una superioridad automática de los algoritmos más complejos sobre los modelos econométricos bien especificados y reestimados dinámicamente, tal y como podemos ver en la Ilustración 24.

En tercer lugar, los hallazgos sugieren que la dinámica del crédito hondureño está fuertemente dominada por su propia inercia temporal. La evidencia de interpretabilidad aplicada al mejor modelo lineal regularizado mostró que los rezagos del propio crédito concentran una parte sustancial de la capacidad predictiva, mientras que las variables macrofinancieras aportan información adicional, pero de menor magnitud relativa. Esto implica que la política monetaria y

las condiciones financieras sí contribuyen al pronóstico, aunque su efecto observable en horizontes cortos opera en interacción con la persistencia interna del sistema crediticio.

En cuarto lugar, el estudio evidenció que el período 2010–2025 no puede tratarse como un régimen homogéneo. Las pruebas inferenciales por subperíodo, junto con el análisis de errores por año, mostraron que el choque asociado a COVID-19 alteró la estabilidad de las relaciones estadísticas y la distribución de los errores de pronóstico. Este resultado justifica metodológicamente el uso de validación temporal estricta, pruebas robustas de comparación predictiva y una interpretación prudente de cualquier conclusión inferencial agregada para todo el período.

En quinto lugar, se constató que la complejidad algorítmica no garantiza mejor desempeño en muestras macroeconómicas relativamente pequeñas. Modelos como Random Forest, XGBoost y MLP exhibieron resultados inferiores frente a especificaciones lineales regularizadas, particularmente cuando se les exigió generalizar fuera de muestra bajo walk-forward. Este hallazgo sugiere que, para series mensuales macrofinancieras con tamaño muestral limitado, alta persistencia y posibles quiebres estructurales, los modelos parsimoniosos y trazables pueden ofrecer una combinación más robusta de precisión, estabilidad e interpretabilidad.

En síntesis, la investigación demuestra que el pronóstico del crédito bancario hondureño mejora cuando se combinan fundamentos macrofinancieros, validación temporal rigurosa e instrumentos de interpretabilidad. No obstante, también muestra que la mejor solución empírica no fue el modelo más complejo, sino aquel que logró equilibrar adecuadamente estructura dinámica, información exógena y capacidad de adaptación a cambios de régimen.

4.5.2 IMPLICACIONES

Los resultados de esta investigación tienen implicaciones metodológicas, analíticas e institucionales. Desde el punto de vista metodológico, el estudio evidencia que la comparación entre modelos solo es válida cuando se realiza bajo un mismo protocolo de validación temporal. Esto implica que, en aplicaciones macrofinancieras, no basta con reportar métricas globales de ajuste o resultados in-sample; es indispensable evaluar el desempeño fuera de muestra con

esquemas consistentes, especialmente en contextos donde existen quiebres estructurales y cambios de régimen como los observados durante y después de la pandemia.

En términos analíticos, los hallazgos sugieren que el crédito bancario agregado en Honduras responde a una combinación de persistencia propia y condiciones macrofinancieras, más que a una relación contemporánea simple con una sola variable de política. Esto tiene una implicación sustantiva para la lectura económica de los resultados: la TPM sí contiene información relevante para el pronóstico, pero su efecto observable no debe interpretarse de manera aislada ni mecánica, sino dentro de un sistema donde intervienen rezagos, tasas del sistema bancario, inflación, tipo de cambio y la propia inercia del crédito. En consecuencia, la formulación de diagnósticos macrofinancieros debe apoyarse en enfoques multivariantes y dinámicos.

Desde la perspectiva de política económica y supervisión financiera, los resultados indican que una herramienta de pronóstico útil para el Banco Central o para instancias de monitoreo macroprudencial no necesariamente debe ser la más compleja, sino la más estable, interpretable y robusta fuera de muestra (Banco Central de Honduras, 2025a). El hecho de que SARIMAX walk-forward haya superado a los demás modelos en la comparación final sugiere que, para fines operativos de seguimiento del crédito agregado, un modelo econométrico reestimado periódicamente puede ofrecer un balance favorable entre precisión, transparencia y facilidad de actualización. A la vez, el desempeño competitivo de modelos como Lasso muestra que el machine learning sí puede complementar el análisis institucional, especialmente cuando se busca identificar variables relevantes, jerarquizar predictores y fortalecer la trazabilidad del proceso analítico.

Asimismo, existe una implicación importante para la gestión del riesgo sistémico. Dado que los errores de pronóstico aumentan en períodos de mayor inestabilidad, los modelos no deben utilizarse como mecanismos automáticos de decisión, sino como instrumentos de apoyo para la vigilancia anticipada. En ese sentido, el valor aplicado del modelo radica no solo en anticipar trayectorias probables del crédito, sino en alertar sobre desalineamientos, cambios de régimen y posibles episodios de aceleración o desaceleración que requieran análisis complementario por parte de la autoridad monetaria y regulatoria.

Finalmente, la investigación aporta una implicación académica relevante: en economías emergentes con información mensual limitada, la superioridad empírica no siempre favorece a los

modelos más sofisticados. Este resultado contribuye al debate sobre la utilidad relativa de econometría y machine learning en series de tiempo macrofinancieras, mostrando que la combinación de parsimonia, validación rigurosa e interpretabilidad puede ser más valiosa que la complejidad algorítmica por sí sola.

4.5.3 TRANSICIÓN AL CAPÍTULO V

Los resultados obtenidos a lo largo del análisis permiten afirmar que el comportamiento del crédito bancario agregado en Honduras responde a una dinámica compleja, en la que convergen persistencia temporal, condiciones macrofinancieras y cambios de régimen. La evidencia inferencial confirmó que el período de estudio no es homogéneo, mientras que la evaluación comparativa mostró que la incorporación de variables exógenas y la validación temporal estricta son elementos decisivos para obtener pronósticos más robustos fuera de muestra. En este marco, el modelo SARIMAX con estrategia walk-forward se consolidó como la alternativa de mejor desempeño predictivo, aunque los modelos lineales de machine learning, en especial Lasso, también demostraron utilidad analítica e interpretativa.

A partir de estos hallazgos, el siguiente capítulo se orienta a integrar las conclusiones sustantivas de la investigación y a traducir los resultados técnicos en recomendaciones concretas. En particular, el Capítulo V retomará la evidencia presentada para: (i) responder de forma directa a la pregunta de investigación y a las hipótesis planteadas, (ii) valorar el cumplimiento del objetivo general y de los objetivos específicos, y (iii) formular recomendaciones aplicables al análisis macrofinanciero y al seguimiento del riesgo sistémico en Honduras. De este modo, la discusión desarrollada en el presente capítulo sirve como puente entre la validación empírica del estudio y las conclusiones estratégicas que fundamentan la utilidad práctica de la investigación.

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

1. Los resultados obtenidos permiten concluir que sí existen variables macroeconómicas y financieras con capacidad informativa para el pronóstico del crédito bancario

agregado hondureño; sin embargo, su aporte debe interpretarse dentro de una dinámica fuertemente dominada por la propia persistencia del crédito. En el análisis exploratorio, el crédito en nivel mostró asociaciones relevantes con las condiciones macrofinancieras, destacando su relación negativa con las tasas del sistema y positiva con el tipo de cambio. En particular, la matriz de correlación evidenció una asociación negativa alta entre el crédito bancario agregado y la tasa pasiva en moneda nacional (-0.888659), así como una asociación positiva elevada entre el crédito bancario agregado y el tipo de cambio nominal de venta (0.855659), lo que confirma que el comportamiento del crédito no es ajeno al entorno monetario y financiero.

No obstante, al pasar del plano descriptivo al predictivo, el hallazgo principal es que la serie de crédito presenta una inercia temporal muy marcada. El análisis SHAP del modelo Lasso mostró que la variable más importante fue el rezago inmediato del logaritmo del crédito, con una importancia media de 0.874377, muy por encima de cualquier variable macrofinanciera.

Solo en un segundo plano aparecieron la tasa pasiva en moneda nacional rezagada tres períodos, la tasa pasiva en moneda nacional rezagada cuatro períodos y el tipo de cambio nominal de venta contemporáneo, con contribuciones considerablemente menores. Esto indica que, aunque las variables macrofinancieras sí añaden información relevante, la capacidad predictiva del sistema está explicada principalmente por la continuidad del propio crédito y, de manera complementaria, por algunas señales rezagadas de tasas pasivas y tipo de cambio. En consecuencia, el objetivo específico 1 se considera cumplido, pero con una precisión importante: las variables macrofinancieras son predictivamente útiles, aunque su efecto es secundario frente a la fuerte persistencia autorregresiva del crédito.

2. Los resultados obtenidos permiten concluir que sí fue posible desarrollar modelos de pronóstico fuera de muestra con alto desempeño para el crédito bancario agregado hondureño; sin embargo, la evidencia no respalda una superioridad general de las técnicas no lineales de machine learning sobre los enfoques econométricos tradicionales. En la comparación final del análisis, el mejor modelo de machine learning fue Lasso, con un RMSE en nivel de 4,094.59, un MAE en nivel de 3,560.78,

un R^2 de 0.996792 y un R^2 ajustado de 0.990644. Este desempeño superó ampliamente al de los benchmarks econométricos estáticos considerados en la comparación inicial, donde ARIMA registró un RMSE en nivel de 66,191.08 y SARIMAX con variables exógenas un RMSE en nivel de 56,844.53. De igual forma, el modelo Lasso alcanzó un MAPE de 0.5641%, frente a 8.9563% en ARIMA y 7.8489% en SARIMAX con exógenas. En consecuencia, bajo validación fuera de muestra, sí se confirma que al menos un modelo de machine learning puede mejorar de manera sustancial a los modelos econométricos estáticos de referencia.

No obstante, al incorporar el protocolo más exigente de evaluación temporal del análisis, el resultado adquiere un matiz más importante: el mejor desempeño ya no proviene de la complejidad algorítmica en sí misma, sino de la combinación entre parsimonia, regularización y actualización secuencial. En ese esquema, el modelo Lasso con validación temporal walk-forward obtuvo el menor RMSE en nivel (3,503.77) y el mayor R^2 ajustado en nivel (0.997637) entre los modelos comparados, mientras que el modelo SARIMAX con validación temporal walk-forward quedó muy cerca, con un RMSE en nivel de 3,724.16 y un R^2 ajustado de 0.996836; además, este último mostró una ligera ventaja en MAE en nivel y MAPE en nivel. Por tanto, el objetivo específico 2 se considera cumplido parcialmente: sí se comprobó que al menos un modelo de machine learning puede alcanzar e incluso mejorar marginalmente el mejor desempeño econométrico en algunas métricas, pero no se demostró una superioridad contundente ni general de los modelos no lineales. De hecho, los resultados indican que los modelos más robustos fueron el Lasso con validación temporal y el SARIMAX con validación temporal, mientras que algoritmos de mayor complejidad, como Random Forest, XGBoost y MLP, exhibieron resultados claramente inferiores o inestables. En consecuencia, la principal lección empírica del estudio es que la mejora predictiva provino, sobre todo, de la validación temporal estricta, la reestimación dinámica y la parsimonia del modelo, más que de la sofisticación algorítmica por sí sola.

3. Los resultados obtenidos permiten concluir que el objetivo específico 3 se cumplió, ya que fue posible identificar y jerarquizar de manera explícita la contribución de las

variables predictivas dentro del mejor modelo de machine learning. En la comparación de desempeño fuera de muestra, el modelo Lasso fue el mejor entre los modelos de machine learning evaluados, al registrar un RMSE en nivel de 4,094.59, un MAE en nivel de 3,560.78, un MAPE de 0.5641%, un R^2 de 0.996792 y un R^2 ajustado de 0.990644, superando claramente a los otros modelos de ML considerados en el mismo ejercicio.

La evidencia de interpretabilidad muestra que la predicción del modelo estuvo explicada principalmente por la propia persistencia del crédito. En particular, la variable con mayor importancia SHAP fue el rezago inmediato del logaritmo del crédito, con una importancia media de 0.874377, muy por encima del resto de predictores. Solo en un segundo plano aparecieron la tasa pasiva en moneda nacional rezagada tres períodos (0.005505), la tasa pasiva rezagada cuatro períodos (0.000521) y el tipo de cambio nominal de venta contemporáneo (0.000163). Por tanto, los resultados indican que, aunque las variables macrofinancieras sí aportan información incremental, la mayor capacidad predictiva del mejor modelo descansa en la continuidad temporal de la propia trayectoria del crédito. Desde el punto de vista económico, este hallazgo sugiere que el crédito bancario agregado hondureño funciona como una serie de fuerte inercia, donde los movimientos recientes del propio crédito contienen más información predictiva que los cambios contemporáneos de política monetaria o de otras variables del entorno (Mishkin, 2022). Sin embargo, la presencia de la tasa pasiva rezagada y del tipo de cambio entre las variables con aporte positivo confirma que las condiciones macrofinancieras no son irrelevantes, sino complementarias. En ese sentido, la interpretabilidad del modelo permitió traducir el resultado técnico en una lectura económica defendible: el crédito agregado en Honduras depende, en primer lugar, de su propia dinámica reciente y, en segundo término, de señales rezagadas del sistema financiero y del entorno cambiario (Ozgur & Aslan, 2025). En consecuencia, la hipótesis específica relacionada con interpretabilidad y trazabilidad se considera respaldada, ya que las técnicas explicativas sí aportaron claridad adicional sobre la contribución relativa de los predictores del mejor modelo.

5.2 RECOMENDACIONES

1. Derivación de la Conclusión 5.1.2: implementar un sistema institucional de pronóstico con validación temporal y actualización recurrente.

Dado que los mejores resultados del estudio se obtuvieron bajo esquemas de validación temporal, se recomienda que las instituciones que monitorean el crédito bancario agregado hondureño adopten un sistema de pronóstico basado en reestimación periódica y no en modelos estáticos. La evidencia mostró que el modelo Lasso con validación temporal alcanzó el menor RMSE en nivel (3,503.77) y el mayor R^2 ajustado en nivel (0.997637), mientras que el modelo SARIMAX con validación temporal presentó un desempeño muy cercano, con RMSE en nivel de 3,724.16 y R^2 ajustado de 0.996836.

En consecuencia, se recomienda implementar un flujo automatizado que incorpore mensualmente la información más reciente de crédito, tasas del sistema, inflación y tipo de cambio, y que reentrene de forma recurrente al menos un modelo de machine learning parsimonioso y un modelo econométrico dinámico. Esta recomendación responde directamente al hallazgo central del estudio: la mejora predictiva provino, sobre todo, del respeto del orden temporal de los datos y de la actualización secuencial de parámetros.

2. Derivación de las Conclusiones 5.1.2 y 5.1.3: priorizar modelos parsimoniosos e interpretables para el uso operativo y analítico.

Se recomienda que, para fines de proyección y seguimiento macrofinanciero, se privilegien modelos parsimoniosos, robustos e interpretables, especialmente Lasso, en lugar de algoritmos de mayor complejidad cuya estabilidad no fue confirmada empíricamente. En el ejercicio comparativo con validación temporal, modelos como Random Forest, XGBoost y MLP mostraron desempeños sustancialmente inferiores al de Lasso y SARIMAX, lo que indica que la complejidad algorítmica no garantiza mejor capacidad predictiva en este contexto.

Además, la interpretabilidad del mejor modelo mostró que la predicción estuvo dominada por la persistencia del propio crédito, mientras que en un segundo plano aparecieron la tasa pasiva rezagada y el tipo de cambio nominal de venta como señales complementarias. Por tanto, se recomienda que la selección final de modelos no se

base únicamente en métricas de error, sino también en su capacidad de explicar de forma económicamente defendible cuáles variables sostienen el pronóstico.

3. Derivación de la Conclusión 5.1.1: fortalecer el monitoreo macrofinanciero más allá de la TPM, incorporando tasas del sistema y tipo de cambio.

Dado que los resultados del estudio muestran que las variables macrofinancieras sí aportan información relevante al pronóstico, aunque en un papel complementario frente a la fuerte persistencia del crédito, se recomienda ampliar el seguimiento institucional más allá de la TPM e incorporar de forma sistemática la evolución de las tasas pasivas y del tipo de cambio nominal de venta. En el análisis empírico, el crédito mostró una relación negativa elevada con la tasa pasiva y una relación positiva elevada con el tipo de cambio, mientras que ambas variables también aparecieron entre los predictores con aporte adicional dentro del mejor modelo interpretable.

En términos prácticos, esto implica que los sistemas de monitoreo y alerta temprana deberían incluir no solo la trayectoria de la política monetaria, sino también el comportamiento de las tasas del sistema financiero y del mercado cambiario, especialmente en contextos de mayor volatilidad o posibles cambios de régimen. De esta manera, las proyecciones de crédito podrían apoyarse en una lectura más amplia y realista de las condiciones macrofinancieras que afectan al sistema bancario hondureño.

CAPÍTULO VI. APLICABILIDAD

6.1 NOMBRE DE LA PROPUESTA

Modelo de implementación de un sistema institucional de pronóstico dinámico y recurrente del crédito bancario agregado para el Banco Central de Honduras basado en regresión lineal regularizada Lasso.

6.2 JUSTIFICACIÓN DE LA PROPUESTA

La presente propuesta se fundamenta directamente en los hallazgos empíricos del estudio. Las conclusiones del Capítulo V demostraron que el mejor desempeño predictivo fuera de muestra se obtuvo bajo esquemas de validación temporal estricta y reestimación dinámica, no bajo modelos estáticos de mayor complejidad algorítmica. En la comparación final, el modelo Lasso con estrategia walk-forward alcanzó un RMSE en nivel de 3,503.77 y un R^2 ajustado de 0.997637, mientras que SARIMAX con walk-forward obtuvo resultados muy cercanos (RMSE 3,724.16; R^2 ajustado 0.996836). Ambos modelos superaron ampliamente a los modelos estáticos de referencia: ARIMA registró un RMSE en nivel de 66,191.08 y SARIMAX con variables exógenas de 56,844.53. Esta evidencia establece que la mejora predictiva no provino de la sofisticación algorítmica, sino de la combinación entre parsimonia, regularización y actualización secuencial de parámetros.

El análisis de interpretabilidad mediante SHAP reveló, además, que la predicción del mejor modelo estuvo dominada por la persistencia del propio crédito: el rezago inmediato del logaritmo del crédito registró una importancia media de 0.8744, muy por encima de cualquier variable macrofinanciera. En un segundo plano, la tasa pasiva en moneda nacional rezagada tres y cuatro períodos, y el tipo de cambio nominal de venta, contribuyeron de forma complementaria. Este hallazgo tiene una implicación directa para el diseño de la propuesta: un sistema institucional efectivo debe privilegiar la actualización periódica de la serie de crédito, incorporar las señales rezagadas del sistema financiero y del entorno cambiario, y evitar la dependencia de esquemas que asuman relaciones lineales estables o que no se recalibren regularmente.

TABLA 15 Fundamentos de la propuesta

Hallazgos que fundamentan la propuesta (Cap. IV y V)
El modelo Lasso walk-forward obtuvo el mejor desempeño predictivo (RMSE 3,503.77; MAPE 0.56%) entre todos los modelos evaluados bajo validación temporal.
Los modelos de mayor complejidad (Random Forest, XGBoost, MLP) mostraron desempeños inferiores o inestables, confirmando la superioridad de la parsimonia en este contexto.
La persistencia autorregresiva del crédito domina el pronóstico (importancia SHAP 0.8744), con contribución complementaria de tasas rezagadas y tipo de cambio.
La validación temporal walk-forward es condición necesaria para obtener pronósticos robustos: sin ella, el error se multiplica por un factor de hasta 19x (ARIMA estático vs. Lasso walk-forward).

Fuente: elaboración propia.

Desde el plano teórico, la propuesta se sustenta en tres cuerpos conceptuales del marco teórico de la investigación. En primer lugar, la teoría del canal de crédito y el mecanismo de transmisión de la política monetaria (International Monetary Fund, 2024) establecen que los cambios en la tasa de política monetaria afectan el volumen del crédito a través de rezagos temporales, fricciones financieras y mecanismos indirectos, lo que justifica el uso de modelos multivariados con variables rezagadas como los implementados en el estudio. En segundo lugar, el enfoque del acelerador financiero de (Bernanke et al., 1998; Kiyotaki & Moore, 1997) postula que pequeñas variaciones en las condiciones financieras pueden amplificarse a través del sistema bancario y generar ciclos del crédito no lineales. Esta base teórica respalda empíricamente que las relaciones entre la TPM y el crédito no sean proporcionales ni constantes en el tiempo, lo que a su vez justifica el uso de técnicas de regularización y validación temporal como las empleadas en el estudio. En tercer lugar, la teoría de la información asimétrica de (Stiglitz & Weiss, 1981) explica por qué los bancos ajustan cantidades de crédito antes que tasas ante cambios en las condiciones monetarias, lo que sustenta que la variable dependiente del sistema sea el crédito total al sector privado y no las tasas de interés.

Desde la perspectiva del aprendizaje estadístico, la propuesta se alinea con el principio de que, en contextos de muestra limitada y alta persistencia temporal como el hondureño, los modelos parsimoniosos y regularizados superan a los algoritmos de mayor complejidad. Los resultados del estudio lo confirmaron: en la comparación bajo validación temporal, Lasso superó a Random Forest, XGBoost y MLP en todas las métricas relevantes. En ese marco, la utilización de Lasso como componente central del sistema no responde a una elección arbitraria, sino a la evidencia empírica generada en el propio estudio, reforzada por la recomendación explícita del Capítulo V de priorizar modelos parsimoniosos e interpretables para el uso operativo y analítico institucional.

Las recomendaciones del Capítulo V establecieron con precisión los tres lineamientos que articulan directamente la propuesta del Capítulo VI: (i) implementar un sistema institucional de pronóstico con validación temporal y actualización recurrente, derivado de la Conclusión 5.1.2; (ii) priorizar modelos parsimoniosos e interpretables especialmente Lasso para el uso operativo y analítico, derivado de las Conclusiones 5.1.2 y 5.1.3; y (iii) fortalecer el monitoreo

macrofinanciero incorporando tasas del sistema y tipo de cambio más allá de la TPM, derivado de la Conclusión 5.1.1. La presente propuesta constituye la respuesta aplicada y operativizada a estos tres lineamientos, diseñada específicamente para el contexto institucional del Banco Central de Honduras.

La viabilidad de la propuesta descansa en tres elementos concretos. Primero, utiliza exclusivamente series oficiales del BCH crédito total al sector privado, TPM, tasas activa y pasiva, inflación interanual y tipo de cambio nominal de venta disponibles con periodicidad mensual definida, lo que elimina dependencias externas y garantiza la continuidad operativa del sistema. Segundo, se apoya en un flujo metodológico reproducible, documentable y auditable que puede ser ejecutado por el equipo técnico existente sin requerir infraestructura tecnológica intensiva, gracias a la adopción de Streamlit como capa de visualización. Tercero, no exige un cambio de paradigma incompatible con el análisis macroeconómico institucional, sino que se plantea como un instrumento complementario de pronóstico y alerta temprana que fortalece sin sustituir el juicio experto de los analistas.

En términos de impacto esperado, la implementación de la propuesta permitiría al BCH disponer de un sistema que, bajo condiciones similares a las del período de estudio, genera pronósticos del crédito bancario agregado con un error porcentual medio absoluto (MAPE) inferior al 1% bajo el esquema de validación temporal empleado (MAPE Lasso walk-forward = 0.5641%). Este nivel de precisión representa una mejora de más de 15 veces respecto al error que se obtendría con modelos estáticos convencionales, lo que se traduce en una capacidad sustancialmente superior para anticipar cambios en la trayectoria del crédito, apoyar la formulación de escenarios macrofinancieros y mejorar la oportunidad del seguimiento de la transmisión de la política monetaria. Al privilegiar un enfoque interpretable y metodológicamente transparente, la propuesta facilita, además, traducir los resultados cuantitativos del modelo en análisis económico sustantivo, evitando la dependencia de esquemas opacos o de difícil validación institucional (Mishkin, 2022).

En términos operativos, la propuesta se justifica porque reduce de manera importante la incertidumbre asociada al pronóstico del crédito bancario agregado. Tomando como referencia el saldo observado al cierre de la muestra (L. 739,231.51 millones), un error porcentual medio absoluto de 0.5641% representa una desviación aproximada de L. 4,170 millones, mientras que

errores como los registrados por ARIMA estático (8.9563%) o SARIMAX estático (7.8489%) representan desviaciones del orden de L. 66,208 millones y L. 58,021 millones, respectivamente. Por tanto, la propuesta no se justifica únicamente por mostrar mejores métricas estadísticas, sino porque reduce el rango de error esperado del pronóstico a magnitudes operativamente más manejables para el seguimiento macrofinanciero. Esta reducción del error no equivale por sí sola a una disminución automática del riesgo de liquidez, pero sí mejora la precisión del insumo técnico utilizado para construir escenarios y apoyar la vigilancia institucional del crédito.

Aunque el modelo Lasso mostró el menor RMSE en la comparación final, la prueba de Diebold-Mariano robusta indicó que su diferencia frente a SARIMAX con validación temporal no fue estadísticamente significativa; por ello, la propuesta se justifica no como la imposición de un único algoritmo, sino como la implementación de un sistema parsimonioso, actualizable e interpretable, sustentado en los enfoques que demostraron mayor robustez bajo validación temporal estricta.

Con el propósito de sintetizar visualmente los fundamentos que sustentan la presente propuesta, la ilustración 25 presenta un diagrama de causas que organiza los seis ejes de justificación identificados en esta sección. El diagrama integra tanto la evidencia empírica obtenida en el estudio incluyendo los resultados cuantitativos de desempeño predictivo del Capítulo IV como las limitaciones de los enfoques estáticos tradicionales, el contexto macroeconómico hondureño, la brecha institucional existente en el BCH, la dinámica autorregresiva del crédito y el sustento teórico del marco conceptual del Capítulo II. La convergencia de estos seis ejes hacia un efecto común permite demostrar que la propuesta no responde a una decisión arbitraria, sino a una necesidad técnica, empírica e institucional plenamente justificada.

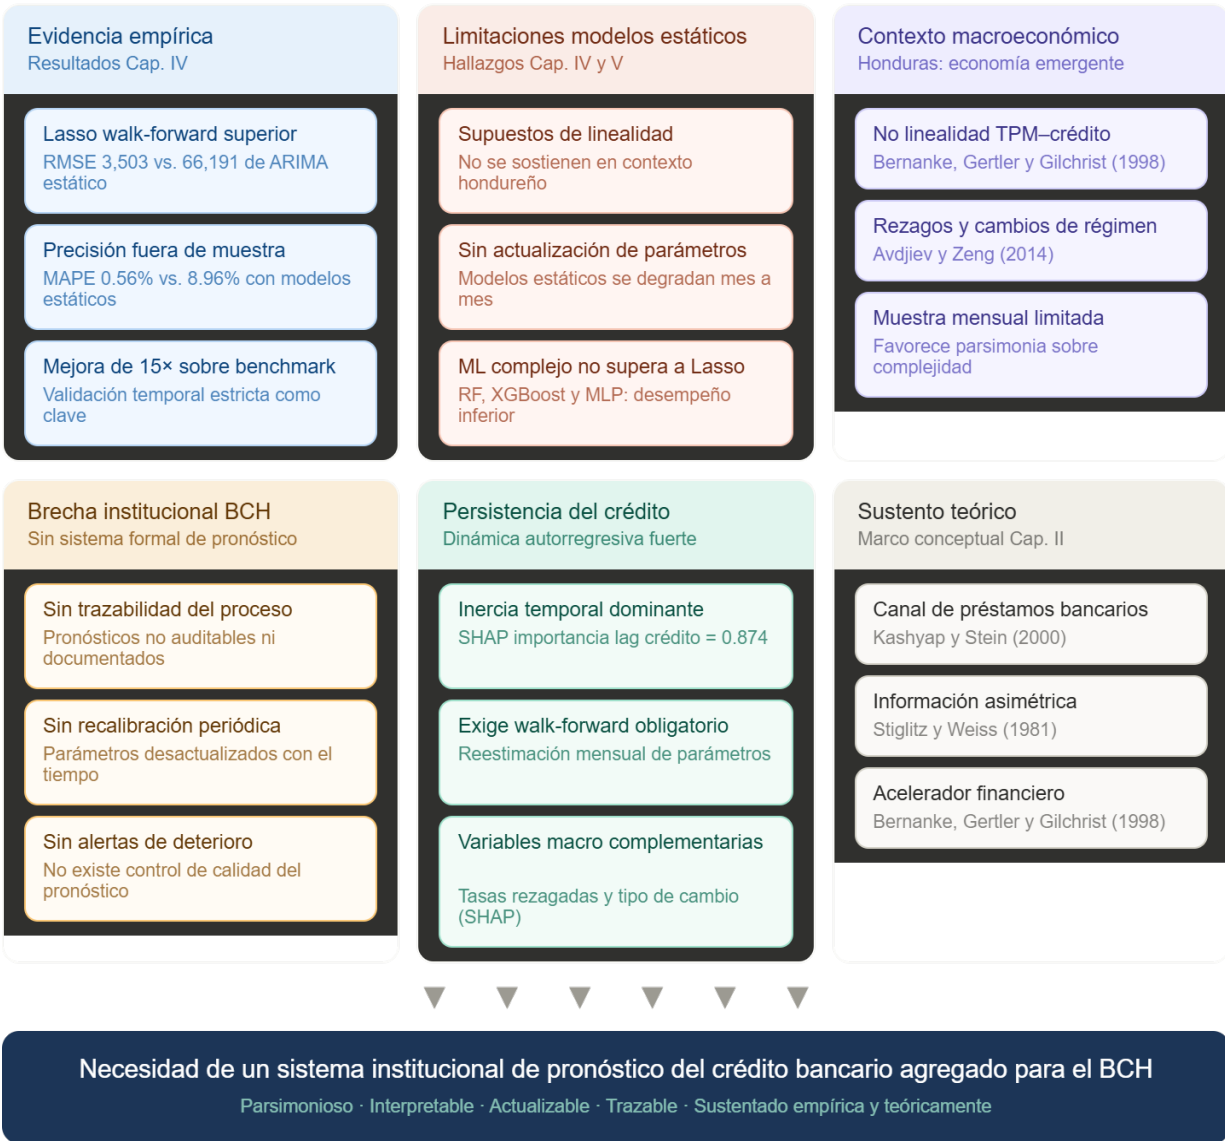


ILUSTRACIÓN 26 Causas fundamentales para la justificación de la propuesta

Fuente: elaboración propia.

6.3 ALCANCE DE LA PROPUESTA

El alcance de la presente propuesta comprende el diseño metodológico, la estructuración operativa y la formulación del esquema de implementación de un sistema institucional de pronóstico del crédito bancario agregado en Honduras, orientado al uso técnico del Banco Central de Honduras como herramienta de apoyo para el monitoreo macrofinanciero y el análisis prospectivo. La propuesta se enfoca en la construcción de un sistema reproducible, interpretable y actualizable periódicamente, sustentado en series macrofinancieras oficiales del BCH y en los hallazgos empíricos obtenidos en la investigación.

La propuesta se circunscribe al crédito bancario agregado al sector privado y a variables macrofinancieras de frecuencia mensual disponibles en fuentes oficiales del Banco Central de Honduras. En consecuencia, no contempla el pronóstico a nivel de banco individual, segmento de cliente, actividad económica específica ni decisiones automatizadas de política monetaria o regulación financiera. Tampoco sustituye el análisis técnico de los especialistas, sino que se plantea como un instrumento complementario para fortalecer la vigilancia anticipada, la generación de escenarios y la trazabilidad del proceso de pronóstico.

6.3.1 OBJETIVO GENERAL DEL PROYECTO

Garantizar la operación mensual continua, reproducible y auditable del sistema institucional de pronóstico dinámico y recurrente del crédito bancario agregado del Banco Central de Honduras, asegurando que cada ciclo de actualización genere pronósticos con $MAPE \leq 1.0\%$ y sean entregados dentro de los cinco días hábiles posteriores a la publicación de las series oficiales del BCH.

6.3.2 OBJETIVOS ESPECIFICOS DEL PROYECTO

- Ejecutar mensualmente el proceso de extracción, transformación y carga (ETL) de las seis variables macrofinancieras oficiales del BCH en menos de dos horas tras la publicación de las series, garantizando la integridad y consistencia de la base maestra del sistema.
- Reestimar y validar el modelo Lasso walk-forward en cada ciclo mensual, documentando el hiperparámetro λ seleccionado, las variables activas y el MAPE obtenido en la bitácora técnica del sistema.
- Generar y distribuir el reporte mensual de pronóstico dentro del plazo institucional definido, incluyendo el pronóstico puntual $t+1$, el intervalo de confianza al 95%, las métricas de desempeño y las alertas del sistema.
- Activar el protocolo de recalibración extraordinaria cuando el MAPE supere el umbral amarillo (1.0%–2.5%) por dos ciclos consecutivos o el umbral rojo ($> 2.5\%$) en un ciclo.

- Mantener actualizada la aplicación Streamlit en cada ciclo, asegurando que los cinco módulos de visualización reflejen los datos y métricas del pronóstico más reciente dentro del mismo plazo de entrega del reporte.

6.4 DESCRIPCIÓN Y DESARROLLO

6.4.1 DESCRIPCIÓN

La propuesta consiste en el diseño e implementación de un sistema institucional de pronóstico del crédito bancario agregado en Honduras, concebido como herramienta de apoyo al monitoreo macrofinanciero y al análisis prospectivo del BCH. Su finalidad es generar proyecciones periódicas del comportamiento del crédito a partir de información oficial, mediante un enfoque metodológico reproducible, interpretable y actualizable, que facilite la lectura económica de los resultados y su utilización dentro de procesos formales de análisis técnico.

El sistema se estructura como un flujo analítico compuesto por las siguientes etapas: integración de datos, preparación y transformación de series, modelado predictivo, validación y evaluación, generación de reportes y visualización interactiva. Esta arquitectura responde directamente a los requerimientos identificados en la investigación: trabajar con una base mensual oficial depurada y documentada, aplicar transformaciones, rezagos y control de colinealidad, y ejecutar validación temporal estricta, dado que las series exhiben persistencia, no normalidad, cambios de régimen y relaciones dinámicas entre variables monetarias y financieras.

Desde el punto de vista metodológico, la propuesta no ofrece un modelo aislado, sino un sistema institucional que combina una arquitectura predictiva parsimoniosa e interpretable con una capa de visualización ligera, flexible y de bajo costo operativo. En coherencia con los hallazgos del estudio, el modelo Lasso se utiliza como componente central del esquema predictivo por su capacidad de selección de variables y trazabilidad, sin presentarlo como solución exclusiva. La incorporación de Streamlit fortalece la viabilidad de la propuesta al permitir el desarrollo de una interfaz analítica orientada al usuario institucional sin requerir infraestructura pesada para reportería y visualización, en consonancia con la lógica general del estudio, donde las soluciones parsimoniosas y replicables resultaron más defendibles que las alternativas innecesariamente complejas.

La Figura 26 presenta el diagrama de arquitectura de despliegue del sistema institucional de pronóstico dinámico y recurrente del crédito bancario agregado del Banco Central de Honduras. La arquitectura se organiza en cinco componentes principales desplegados íntegramente dentro del perímetro institucional del BCH, sin dependencia de infraestructura de nube pública para el procesamiento ni el almacenamiento de datos oficiales.

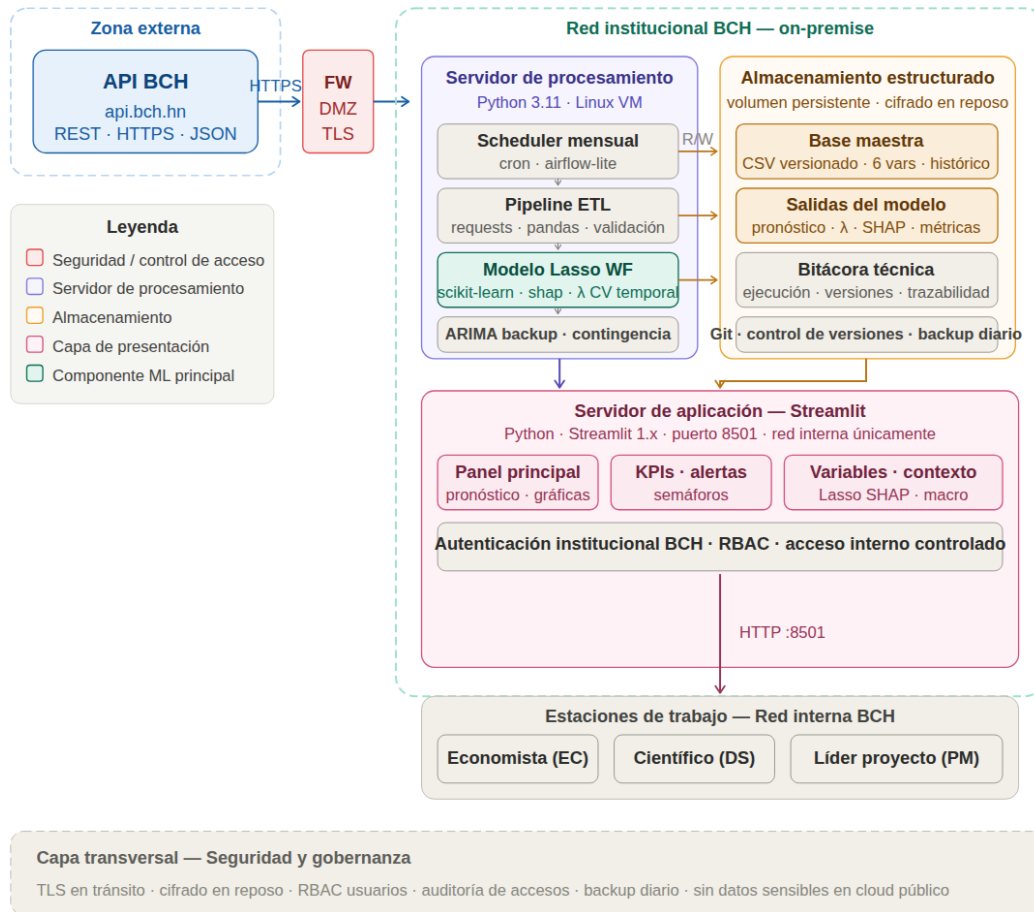


ILUSTRACIÓN 27 Diagrama de arquitectura de despliegue

Fuente: Elaboración propia.

6.4.2 DESARROLLO

Para el desarrollo del sistema predictivo se adopta el lineamiento metodológico CRISP-DM (Cross-Industry Standard Process for Data Mining), estándar ampliamente utilizado en proyectos de analítica avanzada y aprendizaje automático, que resulta apropiado para el contexto

de una institución pública como el BCH por su orientación a la estructuración, iteración y alineación con los objetivos del negocio.

El desarrollo de la propuesta se organiza en seis entregables institucionales concretos, orientados a la implementación operativa del sistema. Estos entregables son: el diseño funcional del sistema, el algoritmo operativo, el protocolo de actualización y recalibración, el formato institucional del reporte de pronóstico, los lineamientos de uso y gobernanza, y la aplicación analítica interactiva en Streamlit para monitoreo y visualización. El siguiente cuadro resume su estructura y propósito.

TABLA 16 Resumen de entregables de la propuesta

Entregable	Objetivo	Contenido principal	Responsable sugerido	Frecuencia / uso
Diseño funcional del sistema	Definir la estructura general del sistema y su propósito institucional.	Objetivo del sistema, variables de entrada, salidas, usuarios y reglas de operación.	PM + EC	Documento base de implementación.
Algoritmo operativo	Estandarizar la secuencia técnica de ejecución.	Extracción, integración, transformación, entrenamiento, validación y documentación.	DS + DE	Ejecución mensual.
Protocolo de actualización y recalibración	Mantener vigente, trazable y estable el sistema.	Reglas de actualización, umbrales de revisión y respuesta ante deterioro.	PM + DS	Aplicación mensual y revisión extraordinaria.
Formato institucional del reporte	Traducir la salida del sistema en un producto útil.	Resumen ejecutivo, pronóstico, métricas, variables relevantes y alertas.	EC + PM	Emisión mensual.
Lineamientos de uso y gobernanza	Asegurar uso correcto y documentado.	Reglas de interpretación, bitácora, control de cambios y límites de uso.	PM + EC	Uso continuo.
Aplicación analítica en Streamlit	Facilitar la visualización y seguimiento institucional.	Módulos de serie observada vs. pronosticada, métricas, variables y alertas.	DE + DS	Consulta periódica.

Fuente: Elaboración propia.

Entregable 1. Diseño funcional del sistema institucional de pronóstico

Define la finalidad del sistema, sus variables de entrada, transformaciones requeridas, salidas esperadas, usuarios institucionales y reglas generales de operación. El sistema tiene como

propósito generar proyecciones mensuales del crédito bancario agregado al sector privado utilizando series oficiales del BCH: crédito total al sector privado, tasa de política monetaria, tasa activa, tasa pasiva, inflación interanual y tipo de cambio nominal de venta. Estas variables conforman un panel integrado validado empíricamente en la investigación y constituyen la base operativa del sistema.

Entregable 2. Algoritmo operativo del sistema de pronóstico

El flujo técnico estandarizado que debe ejecutarse en cada ciclo mensual de actualización del sistema. Su propósito es convertir la operación del sistema en una rutina institucional replicable, auditable y documentada, que pueda ser ejecutada de forma consistente por el equipo técnico del BCH sin necesidad de rediseño metodológico en cada corrida.

Estructura del algoritmo. El algoritmo se organiza en siete fases secuenciales, con dos puntos de control explícitos (decisiones) que determinan si el proceso puede avanzar o debe activar un procedimiento de corrección. La figura siguiente presenta el diagrama de flujo completo.

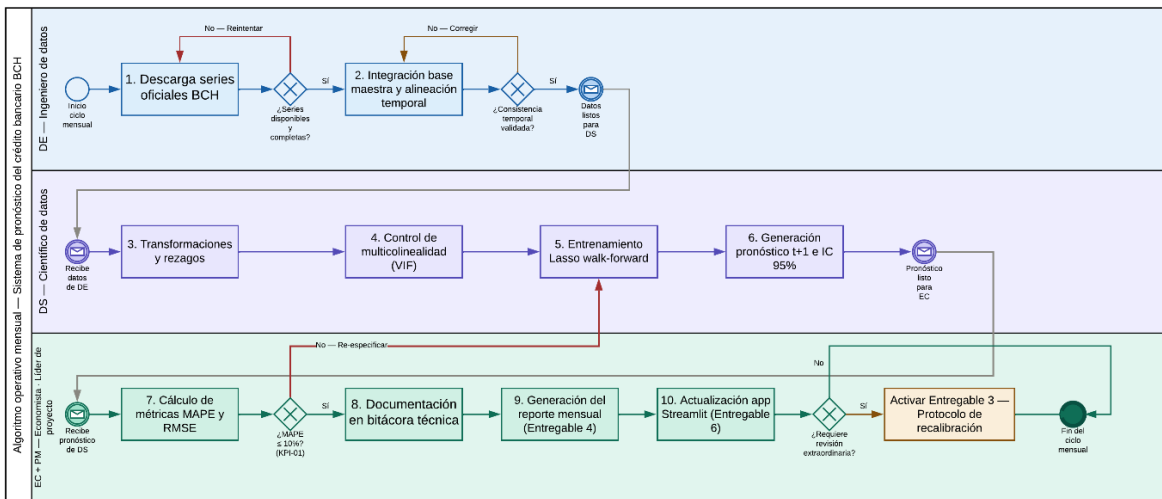


ILUSTRACIÓN 28 BPMN algoritmo operativo mensual

Fuente: elaboración propia.

Descripción de las fases. La Tabla 17 resume las siete fases del algoritmo, sus pasos correspondientes, las actividades técnicas específicas, el criterio de avance requerido para pasar a la fase siguiente y el perfil responsable de su ejecución.

TABLA 17 Resumen de fases del algoritmo operativo mensual

Fase	Pasos	Actividades clave	Criterio de avance	Responsable
1. Datos	1	Descarga API BCH: crédito, TPM, tasas activas/pasiva, inflación, tipo de cambio	Series disponibles y completas	DE
2. Integración	2	Unión temporal de series, alineación de índice de fechas, detección de valores faltantes	Consistencia temporal validada (sin gaps)	DE
3. Preparación	3–4	Logaritmo, diferenciación, rezagos 1–12, estandarización (z-score), control VIF	Predictores sin multicolinealidad severa ($VIF < 5$)	DS
4. Modelado	5–6	Entrenamiento Lasso walk-forward, selección λ por validación cruzada temporal, generación pronóstico t+1	$MAPE \leq 10\%$ (KPI-01 en verde)	DS
5. Validación	7	Cálculo MAPE, RMSE y variación respecto al ciclo anterior	KPIs dentro del umbral; si no, preespecificar	DS + EC
6. Documentación	8	Bitácora técnica, versión del modelo, parámetros λ , variables seleccionadas	Registro completo en bitácora (KPI-05)	DS
7. Salida	9–10	Generación del reporte mensual (Entregable 4) y actualización de la app Streamlit (Entregable 6)	Reporte emitido en plazo (KPI-03)	EC + DE

Fuente: Elaboración propia. DE = ingeniero de datos; DS = científico de datos; EC = economista.

Entregable 3. Protocolo de actualización y recalibración y contingencia

El tercer entregable establece la lógica de mantenimiento del sistema. Se propone una actualización mensual, coherente con la frecuencia de publicación de las series del BCH. En cada ciclo deben incorporarse las nuevas observaciones, regenerarse las transformaciones y rezagos, reestimarse el modelo y verificarse las métricas de control antes de emitir el pronóstico. Si los

errores superan los límites aceptables durante varios ciclos consecutivos, se activa una revisión metodológica de especificación o una comparación con un benchmark econométrico complementario.

Actualización mensual del sistema

Esta se realiza de forma mensual, con coherencia con la frecuencia de las series oficiales del banco central. El proceso consta de 8 pasos secuenciales que abarcan desde la descarga de los indicadores hasta la presentación de los datos en Streamlit. La tabla detalla cada uno de estos pasos.

TABLA 18 Procedimiento de actualización mensual

Paso	Actividad	Criterio de completitud	Herramienta / entregable
1	Descarga de nuevas observaciones desde API BCH	Todas las 6 series disponibles y validadas (KPI-05 = 100%)	Python · requests · bitácora
2	Actualización de la base maestra versionada	Nuevo período incorporado sin inconsistencias temporales	pandas · Git commit etiquetado
3	Regeneración de transformaciones y rezagos	Rezagos 1–12 reconstruidos. Estandarización aplicada.	Pipeline ETL · scikit-learn
4	Reestimación del modelo Lasso walk-forward	λ seleccionado por CV temporal. Variables activas documentadas.	scikit-learn · GridSearchCV
5	Cálculo de métricas KPI-01 y KPI-02	MAPE y variación RMSE calculados. Semáforos actualizados.	Python · bitácora técnica
6	Validación económica del pronóstico	EC confirma coherencia con el contexto macroeconómico del ciclo.	Reunión DS-EC · bitácora
7	Evaluación de la necesidad de recalibración extraordinaria	Si KPI-01 > 1.0% por 2 ciclos consecutivos.	Registro KPI · historial
8	Emisión del pronóstico y actualización de entregables	Reporte mensual (E4) y Streamlit (E6) actualizados y distribuidos.	Entregable 4 y 6

Fuente: Elaboración propia.

Plan de contingencia ante ausencia de variables.

El plan de contingencia define el comportamiento del sistema ante la ausencia temporal de una o más variables de entrada, distinguiendo tres niveles de severidad según la variable afectada y el período de ausencia. Este plan responde directamente a la pregunta: ¿qué hace el sistema si la inflación deja de publicarse un mes? La respuesta no es que el modelo colapse, sino que el sistema

ejecuta un protocolo de degradación controlada que mantiene la continuidad operativa sin comprometer la integridad.

TABLA 19 Plan de contingencia ante ausencia de variables

Nivel	Condición de activación	Acción del sistema	Modelo activo
Nivel 1 Retraso de publicación	Una o más variables exógenas no disponibles en fecha de corte. Se espera publicación en ≤ 5 días hábiles.	Esperar hasta 5 días hábiles adicionales antes de ejecutar el ciclo. El DE monitorea la API BCH diariamente.	Lasso walk-forward (estándar, sin cambio)
Nivel 2 Variable exógena ausente	Una variable exógena (TPM, tasas activas/pasiva, inflación o tipo de cambio) no disponible después del período de espera del Nivel 1. La serie de crédito si está disponible.	(2A) Ejecutar Lasso excluyendo la variable faltante del vector de entrada. Documentar exclusión en bitácora. (2B) Si la exclusión degrada KPI-01 por encima del umbral amarillo, ejecutar ARIMA univariado como pronóstico paralelo de referencia.	(2A) Lasso reducido. (2B) ARIMA univariado como respaldo
Nivel 3 Variable dependiente ausente	La serie de crédito total al sector privado (variable dependiente, indicador 549 BCH) no disponible después del período de espera del Nivel 1.	Suspender la ejecución del ciclo. No emitir pronóstico ni reporte mensual. PM notifica a jefatura en ≤ 24 horas hábiles. El ciclo se reactiva automáticamente tan pronto como la serie esté disponible en la API BCH.	NINGUNO ciclo suspendido. No se emite pronóstico.

Fuente: elaboración propia.

Entregable 4. Formato institucional del reporte de pronóstico

Es un reporte mensual con estructura estándar. Debe incluir un resumen ejecutivo, el pronóstico del período siguiente, la comparación contra el valor observado más reciente, las métricas de desempeño, las variables más relevantes del ciclo y las alertas analíticas pertinentes. Este reporte traduce la salida estadística del sistema en un producto útil para el seguimiento macrofinanciero, evitando que la propuesta quede reducida a una salida puramente cuantitativa. A continuación se presenta el formato institucional propuesto para el reporte mensual de pronóstico del crédito bancario agregado, desarrollado para su aplicación inmediata en cada ciclo mensual de actualización del sistema.

BANCO CENTRAL DE HONDURAS
Sistema Institucional de Pronóstico del Crédito Bancario Agregado
REPORTE MENSUAL DE PRONÓSTICO

Ficha de identificación del reporte

Campo	Detalle
Período de referencia	[Mes] [Año] — Ej: Junio 2026
Fecha de emisión	[DD/MM/AAAA]
Versión del modelo	Lasso walk-forward — $v[X.X]$ $\lambda = [\text{valor}]$
Elaborado por	[Nombre del analista] — [Área / Unidad]
Revisado por	[Nombre del economista senior]
Estado del sistema (semáforo)	[VERDE / AMARILLO / ROJO] — MAPE del ciclo: [X.X]%

Este reporte es un insumo técnico de apoyo al análisis macrofinanciero del BCH. El pronóstico debe interpretarse junto con el juicio experto del equipo técnico y el contexto macroeconómico vigente. No constituye una decisión automática de política.

ILUSTRACIÓN 29 Portada del reporte

Fuente: elaboración propia.

1. Resumen ejecutivo

Pronóstico del crédito bancario agregado para [Mes+1 Año]:

L [XXXX,XXX.X] millones

Variación mensual estimada: [+X.X%] | Variación interanual estimada: [+X.X%]

Valor observado más reciente ([Mes Año]): L [XXXX,XXX.X] millones

Interpretación: [Una a dos oraciones sintetizando la trayectoria del crédito, el contexto macrofinanciero determinante y la dirección del pronóstico. Ejemplo: El sistema anticipa una moderación en el ritmo de crecimiento del crédito, consistente con la postura monetaria restrictiva vigente y la desaceleración observada en la tasa activa durante el trimestre.]

Principales determinantes identificados en este ciclo:

- **TPM:** [Descripción del efecto de la TPM sobre el pronóstico en este ciclo, incluyendo el rezago activo]
- **Tasa activa:** [Efecto sobre la demanda de crédito]
- **Inflación / tipo de cambio:** [Efecto identificado en este ciclo]
- **Alerta activa:** [Indicar si alguna alerta está activa y su implicación para la lectura del pronóstico]

ILUSTRACIÓN 30 Resumen ejecutivo

Fuente: elaboración propia.

2. Pronóstico del período siguiente

La siguiente tabla presenta el pronóstico puntual para el período t+1, el valor observado del período de referencia y el intervalo de confianza al 95% derivado de la distribución de errores del modelo walk-forward.

Variable	Valor observado (t)	Pronóstico (t+1)	Intervalo 95%
Crédito bancario agregado (millones HNL)	L [XXX,XXX.X]	L [XXX,XXX.X]	[XXX,XXX] [XXX,XX]
Variación mensual (%)	[X.X%]	[X.X%]	[X.X%] — [X.X%]
Variación interanual (%)	[X.X%]	[X.X%]	[X.X%] — [X.X%]

Fuente: Sistema institucional de pronóstico del crédito bancario BCH. Modelo Lasso walk-forward, λ seleccionado por validación cruzada temporal. El intervalo de confianza se construye a partir del error estándar de predicción histórico del modelo.

Análisis de la proyección:

[Párrafo de 3 a 5 oraciones describiendo la proyección: nivel estimado, variación esperada respecto al período anterior, lectura en el contexto de la política monetaria vigente y comparación con la trayectoria histórica del crédito. Ejemplo: El sistema proyecta un crecimiento del crédito de X.X% intermensual para julio de 2026, levemente inferior al ritmo de X.X% registrado en junio. Este comportamiento es consistente con el efecto rezagado de los ajustes de la TPM realizados en el primer trimestre del año, cuya transmisión al crédito se refleja con una latencia estimada de 6 a 9 meses según los coeficientes Lasso del ciclo actual.]

ILUSTRACIÓN 31 Pronostico del siguiente periodo

Fuente: elaboración propia.

3. Métricas de desempeño del sistema

Los siguientes indicadores corresponden a los KPIs definidos en la sección 6.5 del sistema. El semáforo de estado refleja el umbral establecido en la ficha metodológica de cada indicador.

KPI	Ciclo actual	Ciclo anterior	Límite (umbral)	Estado
MAPE (%)	[X.X%]	[X.X%]	≤ 10%	[VERDE / AMARILLO / ROJO]
RMSE (millones HNL)	[X,XXX]	[X,XXX]	—	Referencia comparativa
Variación RMSE (%)	[X.X%]	—	≤ 10%	[VERDE / AMARILLO / ROJO]
Oportunidad de actualización	[100% / No]	—	100%	[VERDE / AMARILLO / ROJO]

Fuente: Bitácora técnica del sistema — Ciclo [Mes Año]. Los valores del ciclo anterior corresponden a [Mes anterior Año].

Interpretación del desempeño:

[Párrafo breve interpretando el estado general del sistema. Indicar si el MAPE se mantiene dentro del umbral verde, si hay tendencia de deterioro o mejora respecto a ciclos anteriores, y si es necesario activar algún protocolo de recalibración. Ejemplo: El sistema opera dentro del umbral aceptable de precisión (MAPE = X.X%, estado verde). La variación del RMSE respecto al ciclo anterior se mantiene por debajo del 10%, lo que indica estabilidad técnica. No se activa el protocolo de revisión extraordinaria en este ciclo.]

ILUSTRACIÓN 32 Métricas de desempeño del sistema

Fuente: elaboración propia.

4. Variables relevantes del ciclo

La siguiente tabla presenta las variables seleccionadas por el modelo Lasso en el ciclo actual, junto con su coeficientes estimados y una lectura analítica de su efecto sobre el pronóstico del crédito. Las variables con coeficiente igual a cero fueron excluidas por el proceso de regularización.

Variable	Coef. Lasso (λ selec.)	Dirección del efecto	Lectura analítica
Tasa de política monetaria (TPM) — rezago [k]	[0.XXX]	Negativo / Positivo	[Breve interpretación económica del efecto]
Tasa activa — rezago [k]	[0.XXX]	Negativo / Positivo	[Breve interpretación económica del efecto]
Inflación interanual — rezago [k]	[0.XXX]	Negativo / Positivo	[Breve interpretación económica del efecto]
Tipo de cambio nominal — rezago [k]	[0.XXX]	Negativo / Positivo	[Breve interpretación económica del efecto]
Crédito rezagado — lag [k]	[0.XXX]	Positivo (inercia)	Persistencia estadística de la serie
Variables con coef. = 0 (excluidas por Lasso)	<i>[Lista de variables excluidas en este ciclo]</i>		

Fuente: Coeficientes estimados por el modelo Lasso walk-forward en el ciclo [Mes Año]. λ = [valor]. Los rezagos indicados corresponden al número de períodos de adelanto con el que cada variable entra al modelo.

Cambios respecto al ciclo anterior:

[Indicar si alguna variable entró o salió del modelo en este ciclo respecto al ciclo anterior, y si ese cambio tiene una interpretación económica o responde a variaciones estadísticas en los datos recientes. Ejemplo: En el ciclo actual, la tasa pasiva fue excluida por Lasso (coef. = 0), mientras que el tipo de cambio rezago 3 fue incorporado por primera vez. Este cambio puede estar reflejando una mayor sensibilidad del crédito a las condiciones cambiarias en el contexto de la postura actual de la política monetaria.]

ILUSTRACIÓN 33 Variables relevantes del ciclo

Fuente: elaboración propia.

5. Alertas del sistema

Las siguientes alertas son evaluadas automáticamente al finalizar cada ciclo de actualización del sistema, de acuerdo con las reglas definidas en el Entregable 3 (protocolo de actualización y recalibración).

Alerta	Descripción	Implicación analítica	Estado
A-01	Aceleración / desaceleración atípica del crédito (>2 desv. estándar respecto a la media histórica)	Revisar contexto macroeconómico; contrastar con expectativas de política monetaria	[ACTIVA / INACTIVA]
A-02	Deterioro del MAPE por encima del umbral amarillo (>10%) durante el ciclo actual	Activar protocolo de recalibración (Entregable 3); notificar jefatura técnica	[ACTIVA / INACTIVA]
A-03	Cambio en variables seleccionadas por Lasso respecto al ciclo anterior (entrada/salida de predictores)	Documentar cambio en bitácora; analizar si responde a cambio estructural o ruido estadístico	[ACTIVA / INACTIVA]
A-04	Contexto de choque externo o cambio de régimen identificado (decisión TPM, choque cambiario, etc.)	Acompañar la lectura del pronóstico con análisis de escenario experto; no usar pronóstico de forma aislada	[ACTIVA / INACTIVA]

Fuente: Elaboración propia. El estado de cada alerta debe ser evaluado por el analista técnico al finalizar la corrida del ciclo y documentado en la bitácora operativa.

ILUSTRACIÓN 34 Alertas del sistema

Fuente: elaboración propia.

6. Contexto macrofinanciero

La siguiente tabla presenta la evolución reciente de las variables macrofinancieras de entrada del sistema para los tres períodos más recientes, con el fin de contextualizar el pronóstico y facilitar su interpretación por parte del equipo técnico.

Variable	Período t-2	Período t-1	Período t	Tendencia
TPM (%)	[X.XX]	[X.XX]	[X.XX]	[Estable / Alza / Baja]
Tasa activa MN (%)	[X.XX]	[X.XX]	[X.XX]	[Estable / Alza / Baja]
Tasa pasiva MN (%)	[X.XX]	[X.XX]	[X.XX]	[Estable / Alza / Baja]
Inflación interanual (%)	[X.XX]	[X.XX]	[X.XX]	[Estable / Alza / Baja]
Tipo de cambio (HNL/USD)	[XX.XX]	[XX.XX]	[XX.XX]	[Estable / Depreciación / Apreciación]

Fuente: Series oficiales del BCH. MN = moneda nacional. Los valores corresponden a datos mensuales oficiales publicados a la fecha de emisión del reporte.

Lectura del contexto:

[Párrafo de 2 a 4 oraciones describiendo el entorno macrofinanciero del período de referencia y su relación con la trayectoria del crédito. Señalar si las condiciones monetarias son restrictivas o expansivas, si ha presiones inflacionarias o cambiarias relevantes, y cómo ese contexto se refleja en el pronóstico generado por el sistema. Este párrafo es el espacio para que el economista senior incorpore su juicio experto sobre la coyuntura.]

ILUSTRACIÓN 35 Contexto macrofinanciero

Fuente: elaboración propia.

7. Notas metodológicas y cierre

Notas técnicas del ciclo:

- [Indicar cualquier ajuste técnico realizado en este ciclo: cambio de ventana de entrenamiento, modificación en el proceso de estandarización, actualización de la fuente de datos, corrección de observaciones atípicas, etc.]
- [Indicar si se activó el protocolo de recalibración (Entregable 3) y el resultado de la revisión.]
- [Indicar si existen limitaciones de datos o advertencias para la interpretación del pronóstico en este ciclo.]

Limitaciones del pronóstico:

El sistema de pronóstico genera proyecciones basadas en patrones históricos y relaciones estadística estimadas sobre la muestra disponible. Su utilidad es mayor en condiciones de continuidad del régimen macroeconómico. En contextos de choque externo, cambio de política monetaria abrupto o ruptura estructura el pronóstico debe acompañarse obligatoriamente con análisis de escenario experto y no debe utilizarse de forma aislada como base de decisión.

Firmas y validación del reporte:

Elaboró	Revisó y validó
<p>[Nombre del analista] Científico de datos / Ingeniero de datos [Fecha]</p>	<p>[Nombre del economista] Economista senior — Área usuaria BCH [Fecha]</p>

Reporte generado por el Sistema Institucional de Pronóstico del Crédito Bancario Agregado — BCH | Entregable 4

ILUSTRACIÓN 36 Nota metodológica y cierre

Fuente: elaboración propia.

Entregable 5. Lineamientos de uso, interpretación y gobernanza

Define las reglas de interpretación y uso institucional del sistema. Establece que el sistema constituye un insumo técnico complementario para el análisis y no un mecanismo automático de decisión. Asimismo, fija la obligación de documentar cada ejecución, registrar cambios metodológicos y acompañar la lectura del pronóstico con juicio experto, especialmente en contextos de choque externo o cambio de régimen macroeconómico.

Entregable 6. Aplicación analítica interactiva en Streamlit

El sexto entregable es una aplicación analítica interactiva desarrollada en *Streamlit*, que sustituye el esquema de *dashboard* de mayor peso tecnológico contemplado en versiones anteriores de la propuesta. La aplicación permite consultar, en una sola interfaz, el crédito observado versus el pronosticado, las principales variables macrofinancieras, las métricas de

desempeño del sistema, los predictores más relevantes del ciclo en curso y las alertas de deterioro o cambio de régimen. Esta solución no altera la esencia metodológica de la propuesta; mejora únicamente la capa de implementación tecnológica, haciéndola más ligera, flexible y viable para un despliegue institucional inicial.

A continuación se muestran cinco mockups de diseño propuestos para cada módulo de la aplicación. Estos contribuyen al prototipo de una interfaz referencial para la implementación del sistema, estos están desarrollados con datos ilustrativos del ciclo de junio del 2026.

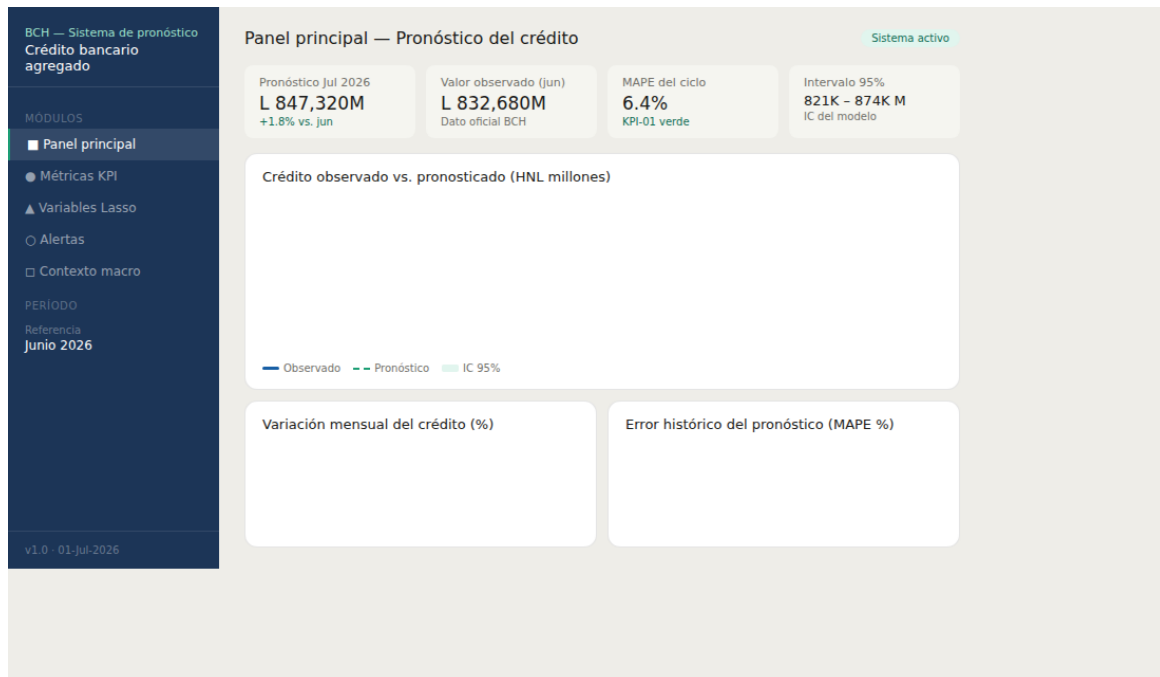


ILUSTRACIÓN 37 Entregable 6 mockup del módulo 1: panel principal

Fuente: Elaboración propia.

Descripción del módulo 1: El panel principal concentra la información central del ciclo mensual. Presenta cuatro tarjetas de resumen (pronóstico t+1, valor observado t, MAPE del ciclo e intervalo de confianza al 95%), la gráfica de la serie de crédito observado versus pronosticado con banda de incertidumbre, y dos gráficas auxiliares de variación mensual y evolución histórica del error MAPE. Es la pantalla de entrada de la aplicación y provee una lectura inmediata del estado del sistema.



ILUSTRACIÓN 38 Entregable 6 mockup del módulo 2: tablero de métricas de desempeño

Fuente: Elaboración propia.

Descripción del módulo 2: El tablero de métricas presenta los tres indicadores clave de desempeño definidos en la sección 6.5 del sistema. Cada KPI incluye su valor actual, una barra de progreso respecto a los umbrales definidos, un semáforo de tráfico verde/ámbar/rojo y una etiqueta de estado. La gráfica inferior muestra la evolución histórica del MAPE y la variación del RMSE durante los últimos seis ciclos, permitiendo identificar tendencias de deterioro o mejora del modelo.

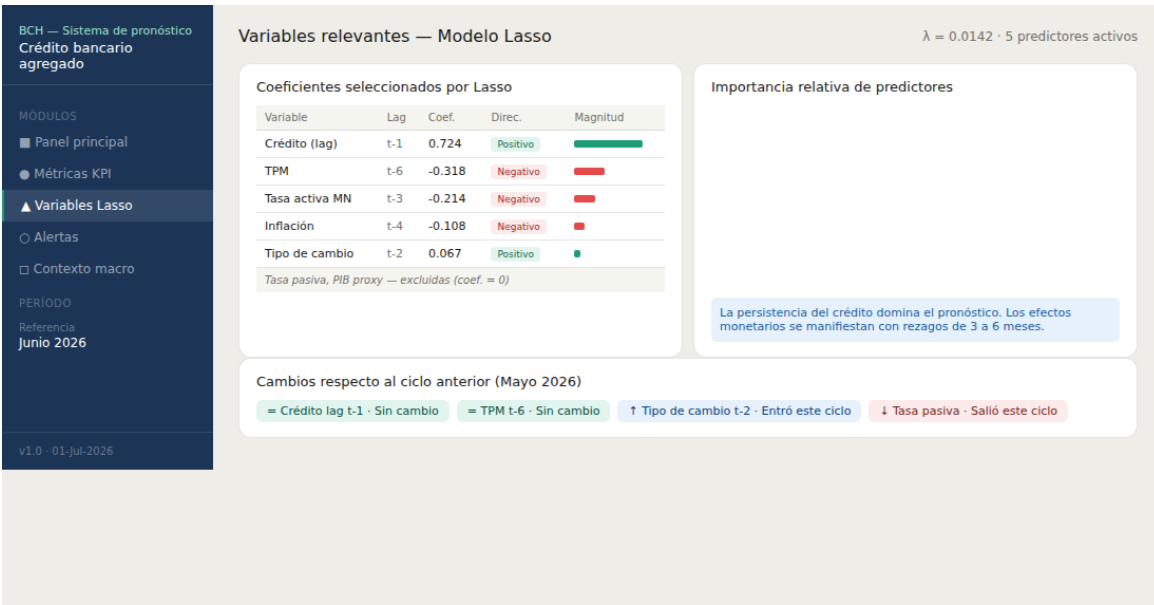


ILUSTRACIÓN 39 Entregable 6 mockup del módulo 3: variables relevantes seleccionadas por el modelo lasso

Fuente: Elaboración propia.

Descripción del módulo 3: El módulo de variables Lasso presenta la tabla de predictores seleccionados en el ciclo con sus coeficientes estimados, rezago activo, dirección del efecto y magnitud relativa. La gráfica de barras horizontales comunica visualmente la importancia relativa de cada predictor. Un panel inferior señala los cambios de variables respecto al ciclo anterior (entradas y salidas del modelo), facilitando el análisis de cambios estructurales en las relaciones macrofinancieras.

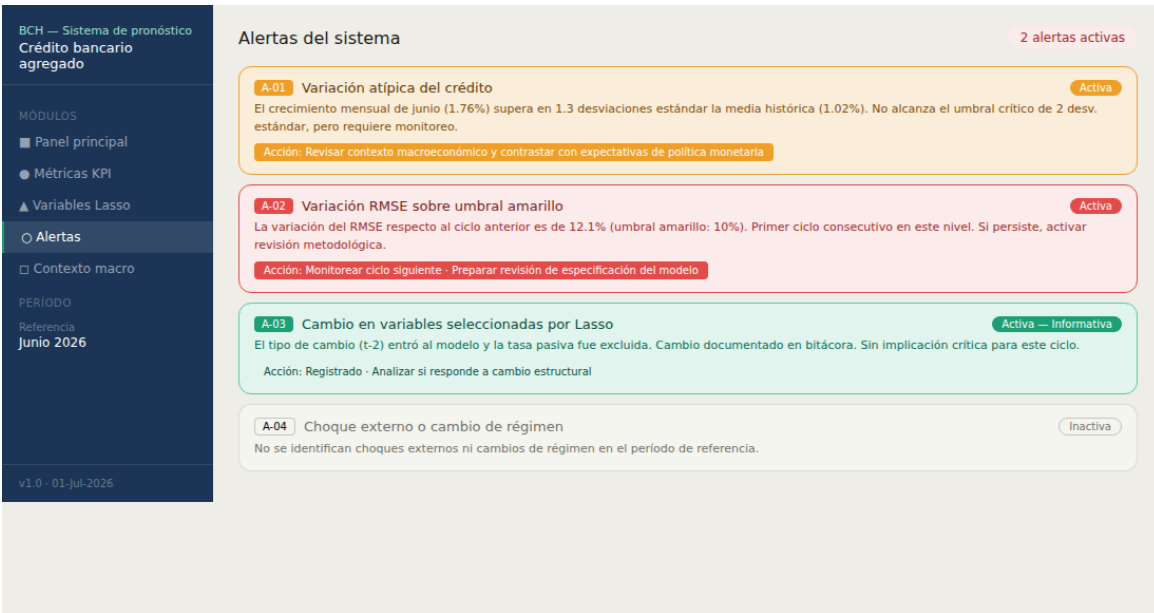


ILUSTRACIÓN 40 Entregable 6 mockup del módulo 4: panel de alertas del sistema con estado activo o inactivo

Fuente: Elaboración propia.

Descripción del módulo 4: El panel de alertas evalúa automáticamente las cuatro alertas del sistema al finalizar cada ciclo. Cada alerta se presenta con código identificador, título, descripción del evento detectado, estado (activa/inactiva) codificado por color (rojo, ámbar, verde informativo, inactivo) y la acción recomendada para el analista. El resumen en la barra lateral indica de forma inmediata cuántas alertas están activas en el ciclo corriente.

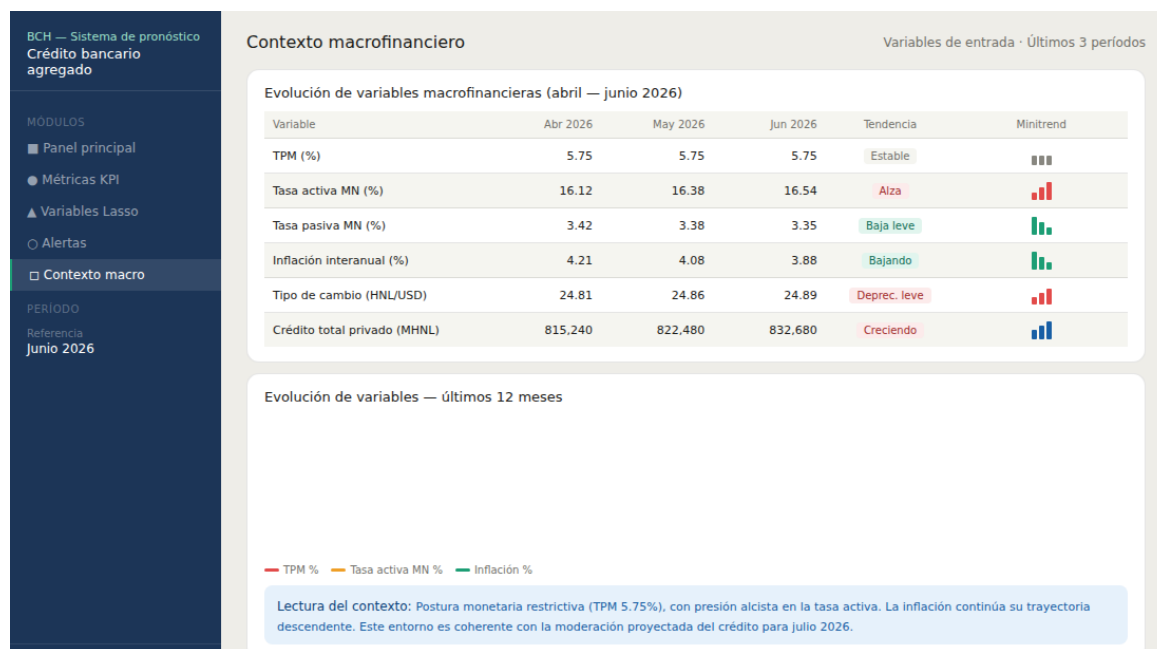


ILUSTRACIÓN 41 Entregable 6 mockup del módulo 5: contexto macrofinanciero

Fuente: Elaboración propia.

Descripción del módulo 5: El módulo de contexto macrofinanciero presenta la tabla de evolución de las seis variables de entrada del sistema para los tres períodos más recientes, con indicadores de tendencia y minitrends visuales. La gráfica de líneas muestra la trayectoria de las principales variables monetarias durante los últimos 12 meses. Un cuadro de lectura analítica provee espacio para que el economista senior registre su interpretación del entorno macroeconómico del ciclo, cumpliendo con el principio de complementariedad entre el pronóstico estadístico y el juicio experto.

Nota: Los mockups presentados corresponden a un prototipo de diseño con datos ilustrativos del ciclo de junio 2026. La implementación definitiva en Streamlit deberá conectarse a las series oficiales del BCH mediante el flujo definido en el Entregable 2 (algoritmo operativo) y adaptarse al entorno tecnológico institucional disponible.

6.5 MEDIDAS DE CONTROL

Con el propósito de evaluar la eficacia, eficiencia, estabilidad y utilidad institucional de la propuesta, se establecen indicadores clave de desempeño orientados a medir tanto el comportamiento técnico del sistema de pronóstico como su funcionamiento operativo, nivel de uso y calidad del proceso analítico.

TABLA 20 Resumen de indicadores de control

Indicador	Código	Tipo	Frecuencia	Meta / umbral
Precisión del pronóstico del crédito bancario	KPI-01	Resultado	Mensual / trimestral	MAPE \leq 1%
Estabilidad del sistema de pronóstico	KPI-02	Resultado	Trimestral	Variación RMSE \leq 10%
Oportunidad de actualización del sistema	KPI-03	Resultado	Mensual	100% de actualización en plazo
Uso analítico efectivo del sistema	KPI-04	Impacto	Trimestral	\geq 80%
Calidad y trazabilidad del dato y del proceso	KPI-05	Estado	Mensual	100%

Fuente: Elaboración propia.

TABLA 21 Ficha metodológica del KPI-01. Precisión del pronóstico del crédito bancario

Campo	Especificación
Nombre del indicador	Precisión del pronóstico del crédito bancario
Código	KPI-01
Tipo de indicador (E-R-I)	Resultado (R)
Definición	Mide el error porcentual medio absoluto entre el valor real observado del crédito bancario agregado y el valor pronosticado por el sistema en cada ciclo de evaluación.
Propósito / importancia estratégica	Evaluar la eficacia técnica del sistema y verificar si mantiene niveles aceptables de precisión para apoyar el monitoreo macrofinanciero.
Fórmula de cálculo	$MAPE = (1/n) \times \sum (Crédito\ real_t - Crédito\ estimado_t) / Crédito\ real_t \times 100$
Componentes de la fórmula	Crédito real _t ; Crédito estimado _t ; n = número de observaciones evaluadas.
Fuentes de datos	Series oficiales del BCH y bitácora de salidas del sistema.
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Mensual, con consolidación trimestral
Responsable de la medición	Analista técnico del sistema
Responsable del resultado	Jefatura del área usuaria
Meta / umbral	Verde: MAPE \leq 10%; Amarillo: 1% < MAPE \leq 2.5%; Rojo: MAPE > 2.5%

Campo	Especificación
Formato de presentación	Tabla de control y gráfico de línea en la aplicación analítica y en el reporte mensual
Notas / consideraciones	Debe interpretarse junto con el contexto macrofinanciero del período
Fecha de creación / revisión	Marzo 2026

Fuente: Elaboración propia.

Tabla 22 Ficha metodológica del KPI-02. Estabilidad del sistema de pronóstico

Campo	Especificación
Nombre del indicador	Estabilidad del sistema de pronóstico
Código	KPI-02
Tipo de indicador (E-R-I)	Resultado (R)
Definición	Mide la variación porcentual del RMSE del sistema entre dos periodos consecutivos de evaluación.
Propósito / importancia estratégica	Detectar deterioro progresivo, pérdida de robustez o necesidad de recalibración del sistema.
Fórmula de cálculo	$\text{Variación RMSE (\%)} = ((\text{RMSE}_t - \text{RMSE}_{t-1}) / \text{RMSE}_{t-1}) \times 100$
Componentes de la fórmula	RMSE _t ; RMSE _{t-1}
Fuentes de datos	Historial de validación del sistema y registro de métricas por ciclo
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Trimestral
Responsable de la medición	Analista cuantitativo responsable del sistema
Responsable del resultado	Coordinación técnica del sistema
Meta / umbral	Verde: variación ≤ 10%; Amarillo: 10% < variación ≤ 20%; Rojo: variación > 20%
Formato de presentación	Tabla comparativa trimestral y gráfico de barras
Notas / consideraciones	Si el indicador permanece en rojo durante dos mediciones consecutivas, debe activarse revisión metodológica
Fecha de creación / revisión	Marzo 2026

Fuente: Elaboración propia.

Tabla 23 Ficha metodológica del KPI-03. Oportunidad de actualización del sistema

Campo	Especificación
Nombre del indicador	Oportunidad de actualización del sistema
Código	KPI-03
Tipo de indicador (E-R-I)	Resultado (R)
Definición	Mide el porcentaje de ciclos mensuales en los que el sistema fue actualizado y ejecutado dentro del plazo institucional previsto.
Propósito / importancia estratégica	Evaluar la eficiencia operativa del sistema y su capacidad de apoyar oportunamente el análisis macrofinanciero.
Fórmula de cálculo	$\text{Oportunidad (\%)} = (\text{Actualizaciones ejecutadas en plazo} / \text{Actualizaciones programadas}) \times 100$
Componentes de la fórmula	Actualizaciones ejecutadas en plazo; Actualizaciones programadas
Fuentes de datos	Bitácora operativa, calendario de actualización y registro de ejecución
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Mensual
Responsable de la medición	Responsable operativo del sistema
Responsable del resultado	Jefatura del área usuaria
Meta / umbral	Verde: 100%; Amarillo: 90%–99%; Rojo: < 90%

Campo	Especificación
Formato de presentación	Tabla de cumplimiento mensual y semáforo operativo
Notas / consideraciones	El plazo puede definirse dentro de los cinco días hábiles posteriores a la disponibilidad de las series
Fecha de creación / revisión	Marzo 2026

Fuente: Elaboración propia.

TABLA 24 Ficha metodológica del KPI-04. Uso analítico efectivo del sistema

Campo	Especificación
Nombre del indicador	Uso analítico efectivo del sistema
Código	KPI-04
Tipo de indicador (E-R-I)	Impacto (I)
Definición	Mide el porcentaje de reportes o consultas generadas por el sistema que son efectivamente utilizadas como insumo en el análisis técnico del crédito bancario.
Propósito / importancia estratégica	Evaluar el grado de adopción institucional de la propuesta y su utilidad práctica para los usuarios finales.
Fórmula de cálculo	Uso efectivo (%) = (Reportes o consultas utilizadas / Reportes o consultas generadas) × 100
Componentes de la fórmula	Reportes o consultas utilizadas; Reportes o consultas generadas
Fuentes de datos	Registro de accesos de la aplicación analítica, bitácora de uso o evidencia de referencia en reportes internos
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Trimestral
Responsable de la medición	Analista de seguimiento del sistema
Responsable del resultado	Dirección o coordinación del área usuaria
Meta / umbral	Verde: ≥ 80%; Amarillo: 60%–79%; Rojo: < 60%
Formato de presentación	Indicador porcentual en tablero de control y reporte trimestral
Notas / consideraciones	Si no existen trazas automáticas, el uso puede documentarse mediante bitácora o referencia explícita en reportes
Fecha de creación / revisión	Marzo 2026

Fuente: Elaboración propia.

TABLA 25 Ficha metodológica del KPI-05. Calidad y trazabilidad del dato y del proceso

Campo	Especificación
Nombre del indicador	Calidad y trazabilidad del dato y del proceso
Código	KPI-05
Tipo de indicador (E-R-I)	Estado (E)
Definición	Mide el porcentaje de ciclos de actualización que cumplen con validación de consistencia, documentación metodológica, control de versiones y registro completo de ejecución.
Propósito / importancia estratégica	Asegurar la confiabilidad de la base maestra, reducir riesgos operativos y fortalecer la trazabilidad analítica del sistema.
Fórmula de cálculo	Calidad y trazabilidad (%) = (Ciclos validados y documentados / Ciclos ejecutados) × 100
Componentes de la fórmula	Ciclos validados y documentados; Ciclos ejecutados
Fuentes de datos	Base maestra, bitácora técnica, registro de versiones y documentación metodológica
Unidad de medida	Porcentaje (%)
Frecuencia de medición	Mensual
Responsable de la medición	Responsable técnico de datos / modelación
Responsable del resultado	Coordinación del sistema o jefatura técnica

Campo	Especificación
Meta / umbral	Verde: 100%; Amarillo: 95%–99%; Rojo: < 95%
Formato de presentación	Lista de verificación mensual y semáforo de control interno
Notas / consideraciones	Es relevante porque el sistema se apoya en un flujo reproducible de descarga, depuración, transformaciones y validación
Fecha de creación / revisión	Marzo 2026

Fuente: Elaboración propia.

6.6 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

El plan de seguimiento organiza la implementación de la propuesta como un proceso institucional por fases orientado al diseño, validación, adopción y puesta en operación del sistema institucional de pronóstico del crédito bancario agregado. Para estimar la duración de implementación se aplica la técnica PERT (Program Evaluation and Review Technique), la cual incorpora incertidumbre temporal mediante tres estimaciones por actividad: tiempo optimista (O), tiempo más probable (M) y tiempo pesimista (P). La duración esperada de cada actividad se calcula con la fórmula $TE = (O + 4M + P) / 6$.

TABLA 26 Cronograma de implementación y seguimiento de la propuesta

Id	Fase	Actividad	Entregable asociado	Responsable	Dependencia	O	M	P	TE
A1	Diagnóstico y alineación	Definición de criterios de éxito, KPIs y alcance operativo	Marco de seguimiento y control	PM + EC	—	0.5	1.0	2.0	1.08
A2	Diagnóstico y alineación	Alineación estratégica con la unidad usuaria del BCH	Validación institucional	PM	A1	0.5	1.0	2.0	1.08
B1	Diseño funcional	Diseño funcional del sistema institucional de pronóstico	Entregable 1	PM + DS + EC	A2	1.0	1.5	3.0	1.67
B2	Diseño funcional	Definición de variables, entradas, salidas y reglas operativas	Entregable 1	DS + EC	B1	1.0	1.5	3.0	1.67
C1	Datos y preparación	Exploración de API BCH y consolidación de series oficiales	Base maestra	DE	B2	1.0	1.5	3.0	1.67
C2	Datos y preparación	ETL, limpieza e integración de base maestra	Entregable 2	DE	C1	1.5	2.5	4.0	2.58
C3	Datos y preparación	Homogeneización, validación de consistencia y control de trazabilidad	Entregable 2	DE + DS	C2	1.0	1.5	3.0	1.67
C4	Datos y preparación	Construcción de transformaciones, rezagos y estandarización	Entregable 2	DS	C3	1.0	2.0	4.0	2.17
D1	Implementación del modelo	Configuración del esquema predictivo principal del sistema	Entregable 2	DS	C4	0.5	1.0	2.0	1.08
D2	Implementación del modelo	Entrenamiento, validación temporal y documentación del componente predictivo	Entregable 2	DS	D1	1.5	2.5	4.5	2.67
D3	Implementación del modelo	Ajuste, trazabilidad y validación económica del modelo	Entregable 2	DS + EC	D2	1.0	2.0	4.0	2.17
E1	Protocolos y control	Elaboración del protocolo de actualización y recalibración	Entregable 3	PM + DS	D3	0.5	1.0	2.0	1.08
E2	Protocolos y control	Diseño de reglas de revisión, alertas y control de deterioro	Entregable 3	DS + EC	E1	0.5	1.0	2.0	1.08
F1	Reportería y visualización	Diseño del formato institucional del reporte mensual	Entregable 4	EC + PM	E2	0.5	1.0	2.0	1.08
F2	Reportería y visualización	Desarrollo de la aplicación analítica interactiva en Streamlit	Entregable 6	DE + DS	F1	1.0	2.0	4.0	2.17
G1	Gobernanza y adopción	Elaboración de lineamientos de uso, interpretación y gobernanza	Entregable 5	PM + EC	F1	0.5	1.0	2.0	1.08
G2	Gobernanza y adopción	Capacitación y socialización con usuarios finales	Adopción institucional	PM + EC + DS	G1, F2	1.0	1.5	3.0	1.67

Id	Fase	Actividad	Entregable asociado	Responsable	Dependencia	O	M	P	TE
H1	Cierre e implementación	Documentación final, bitácora técnica y preparación de puesta en marcha	Cierre operativo	PM + DE	G2	0.5	1.0	2.0	1.08

Fuente: Elaboración propia.




Ilustración 42 Diagrama de Gantt de actividades

Fuente: Elaboración propia. Nota: Duración estimada con método PERT (TE). Días hábiles lunes a viernes. Inicio: 01-Jun-2026.

La secuencia crítica estimada de implementación es A1 → A2 → B1 → B2 → C1 → C2 → C3 → C4 → D1 → D2 → D3 → E1 → E2 → F1 → F2 → G2 → H1. El horizonte gerencial prudente de ejecución se mantiene en 27 semanas, considerando una combinación razonable entre duración esperada, coordinación interfuncional y margen de mitigación de riesgos.

El plan de implementación se estructura en 18 actividades distribuidas en 7 fases, estimadas mediante la técnica PERT con tres tiempos por actividad. La versión anterior calculó únicamente el Tiempo Esperado (TE) de cada actividad. Esta versión incorpora la varianza por actividad ($\sigma^2 = [(P - O) / 6]^2$), la varianza acumulada de la ruta crítica ($\Sigma\sigma^2RC$) y el análisis probabilístico de cumplimiento del cronograma, completando el tratamiento metodológico que la técnica PERT exige.

La ruta crítica comprende 17 de las 18 actividades (A1→A2→B1→B2→C1→C2→C3→C4→D1→D2→D3→E1→E2→F1→F2→G2→H1). La actividad G1 no pertenece a la ruta crítica por tener holgura respecto a G2. Fecha de inicio: 01-Jun-2026. la varianza por actividad ($\sigma^2 = [(P - O) / 6]^2$), la varianza acumulada de la ruta crítica ($\Sigma\sigma^2RC$) y el análisis probabilístico de cumplimiento del cronograma.

TABLA 27 Cronograma PERT varianza por actividad y ruta crítica

ID	Fase	O	M	P	TE	$\sigma=(P-O)/6$	σ^2	R. Crítica	$\Sigma\sigma^2RC$
A1	Diagnóstico y alineación	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
A2	Diagnóstico y alineación	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
B1	Diseño funcional	1.0	1.5	3.0	1.67	0.3333	0.1111	Si	0.1111
B2	Diseño funcional	1.0	1.5	3.0	1.67	0.3333	0.1111	Si	0.1111
C1	Datos y preparación	1.0	1.5	3.0	1.67	0.3333	0.1111	Si	0.1111
C2	Datos y preparación	1.5	2.5	4.0	2.58	0.4167	0.1736	Si	0.1736
C3	Datos y preparación	1.0	1.5	3.0	1.67	0.3333	0.1111	Si	0.1111
C4	Datos y preparación	1.0	2.0	4.0	2.17	0.5000	0.2500	Si	0.2500
D1	Implementación del modelo	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
D2	Implementación del modelo	1.5	2.5	4.5	2.67	0.5000	0.2500	Si	0.2500
D3	Implementación del modelo	1.0	2.0	4.0	2.17	0.5000	0.2500	Si	0.2500
E1	Protocolos y control	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
E2	Protocolos y control	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625

F1	Reportería y visualización	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
F2	Reportería y visualización	1.0	2.0	4.0	2.17	0.5000	0.2500	Si	0.2500
G1	Gobernanza y adopción	0.5	1.0	2.0	1.08	0.2500	0.0625	No	—
G2	Gobernanza y adopción	1.0	1.5	3.0	1.67	0.3333	0.1111	Si	0.1111
H1	Cierre e implementación	0.5	1.0	2.0	1.08	0.2500	0.0625	Si	0.0625
Ruta crítica — 17 actividades					$\mu =$ 27.67 semanas	—	$\Sigma\sigma^2 =$ 2.1667	17	$\sigma = 1.4720$

Fuente: elaboración propia.

Análisis de incertidumbre: Con $\mu = 27.67$ semanas y $\sigma = 1.472$ semanas, la duración del proyecto sigue aproximadamente una distribución normal. La probabilidad de completar el proyecto en el horizonte original de 27 semanas es solo del 32.5%, insuficiente para un proyecto institucional. Aplicando $Z = (T - \mu) / \sigma$ se obtiene la tabla de probabilidades por horizonte.

TABLA 28 Probabilidades de cumplimiento del cronograma por horizonte temporal

Horizonte T	$Z = (T - \mu) / \sigma$	P(completar en T)	P(retraso > T)	Interpretación
27 sem	-0.453	32.5%	67.5%	Objetivo original. TE > T: probabilidad insuficiente. No recomendado.
28 sem	+0.226	59.0%	41.0%	Probabilidad moderada. Margen insuficiente ante imprevistos.
29 sem	+0.906	81.7%	18.3%	Horizonte recomendado ($\mu + 1\sigma$). Alta probabilidad con margen razonable.
30 sem	+1.585	94.4%	5.6%	Conservador. Muy alta certeza de cumplimiento.
31 sem	+2.265	98.8%	1.2%	Muy conservador. Solo ante proyectos con riesgo institucional alto.
32 sem	+2.944	99.8%	0.2%	Riesgo de extenderse > 32 sem = 0.2%. Evento estadísticamente marginal.

Fuente: Elaboración propia.

Ajuste de horizonte la duración esperada de la ruta crítica (27.67 semanas) supera el objetivo original de 27 semanas. El análisis de varianza determina que la probabilidad estadística de cumplir en 27 semanas es únicamente del 32.5%.

Se adopta 29 semanas como horizonte base del proyecto ($\mu + 1\sigma$), con probabilidad de cumplimiento del 81.7%. Nuevo cierre estimado: 21-Dic-2026 (inicio 01-Jun-2026).

Este ajuste impacta únicamente las duraciones de DS y PM (+0.5 mes cada uno), dado que EC y DE finalizan sus actividades antes de la semana 27. El incremento en el presupuesto es del 5.6% respecto al escenario original.

La probabilidad de extenderse más allá de 32 semanas es del 0.2% evento estadísticamente marginal que solo ocurriría ante la concurrencia simultánea de múltiples imprevistos mayores.

6.7 PRESUPUESTO E IMPACTO DE LA PROPUESTA

La implementación de la presente propuesta requiere una estimación financiera que permita valorar su viabilidad operativa dentro del horizonte de adopción institucional definido. En coherencia con la lógica desarrollada a lo largo de este capítulo, el presupuesto no se circunscribe al entrenamiento de un modelo predictivo, sino que abarca los costos asociados al diseño, implementación, documentación, control de calidad, visualización y adopción del sistema institucional de pronóstico del crédito bancario agregado para el Banco Central de Honduras (BCH).

La estructura presupuestal se organiza en dos componentes principales talento humano e infraestructura tecnológica y se complementa con un análisis de incertidumbre bajo la metodología PERT, un cálculo del retorno de la inversión (ROI) adaptado al contexto de la función pública, y un análisis de sensibilidad que evalúa la robustez del modelo financiero ante variaciones en los beneficios estimados.

6.7.1 PRESUPUESTO DE RECURSOS HUMANOS

El componente de talento humano constituye el principal rubro de inversión de la propuesta. La adopción de Streamlit como capa de visualización modifica la arquitectura tecnológica de implementación, pero no reduce la necesidad de perfiles especializados para el diseño, validación, integración y apropiación institucional del sistema. Cada perfil fue dimensionado en función de la carga funcional asignada en la estructura de desglose del trabajo (EDT) presentada en la sección anterior.

Los perfiles contemplados son cuatro: un científico de datos senior (DS), responsable del diseño del esquema predictivo, entrenamiento, validación y documentación técnica del modelo; un economista senior (EC), a cargo de la validación económica de los resultados y de la

elaboración de los lineamientos de uso e interpretación institucional; un ingeniero de datos senior (DE), encargado de la exploración, integración y gobernanza de la base de datos; y un líder de proyecto (PM), responsable de la coordinación interfuncional, comunicación institucional y gestión del cronograma. Las remuneraciones estimadas corresponden a valores de mercado para el sector de consultoría especializada en Honduras.

TABLA 29 Presupuesto de talento humano

Perfil	Cant.	Duración	H/mes	Total HH	Costo total (HNL)
Científico de datos senior (DS)	1	6.5 meses	173	1,124	L 292,500.00
Economista senior (EC)	1	4.0 meses	173	692	L 200,000.00
Ingeniero de datos senior (DE)	1	3.0 meses	173	519	L 105,000.00
Líder del proyecto (PM)	1	6.5 meses (50%)	86	559	L 299,000.00
Subtotal talento humano	4	Prom. 5.0 mes	—	2,894 HH	L 896,500.00

Fuente: Elaboración propia.

6.7.2 PRESUPUESTO DE INFRAESTRUCTURA Y SOFTWARE BAJO ARQUITECTURA LIGERA CON STREAMLIT

La presente propuesta se adopta una arquitectura tecnológica más ligera basada en Streamlit como capa principal de visualización y consulta del sistema. La infraestructura se organiza en componentes más acotados: entorno de despliegue, almacenamiento estructurado, mecanismos de respaldo y versionado, acceso institucional controlado y soporte técnico inicial.

A diferencia de esquemas de visualización más intensivos en servicios administrados en la nube, la presente propuesta adopta una arquitectura tecnológica ligera basada en Streamlit como capa principal de consulta interactiva del sistema. Esta decisión de diseño reduce considerablemente los costos de infraestructura sin comprometer la funcionalidad analítica del sistema, dado que Streamlit permite desplegar aplicaciones de datos con bajo overhead de configuración y mantenimiento.

Los componentes de infraestructura contemplados son: (i) un entorno de despliegue basado en servidor o máquina virtual para alojar la aplicación; (ii) almacenamiento estructurado para la base maestra, las salidas del modelo y los archivos de control; (iii) mecanismos de respaldo y versionado que garanticen la trazabilidad y recuperación ante fallos; (iv) configuración de acceso

institucional interno; y (v) soporte técnico para la estabilización inicial del sistema. Todos los costos se expresan para un horizonte de seis meses, consistente con la duración del proyecto.

TABLA 30 Presupuesto estimado de infraestructura y software con Streamlit

Componente	Costo mensual (HNL)	Duración	Costo total estimado (HNL)
Servidor o máquina virtual de despliegue	L 6,500.00	6.5 meses	L 42,250.00
Base de datos / almacenamiento estructurado	L 2,500.00	6.5 meses	L 16,250.00
Respaldo y versionado	L 1,500.00	6.5 meses	L 9,750.00
Publicación / acceso institucional	L 1,500.00	6.5 meses	L 9,750.00
Soporte técnico e infraestructura menor	L 3,000.00	6.5 meses	L 19,500.00
Total infraestructura	L 15,000.00	6.5 meses	L 97,500.00

Fuente: Elaboración propia, bajo supuestos de arquitectura ligera para despliegue inicial. Los costos deberán ajustarse al entorno tecnológico definitivo disponible en el BCH.

6.7.3 PRESUPUESTO GENERAL

La consolidación de los dos componentes anteriores arroja un presupuesto total en el escenario más probable de L 941,000.00 (novecientos cuarenta y un mil lempiras). El talento humano representa el 90.4% de la inversión total, lo cual es consistente con la naturaleza del proyecto como intervención de alto contenido intelectual y bajo requerimiento de activos físicos.

TABLA 31 Presupuesto general de la propuesta

Categoría	Monto HNL
Recursos humanos	L 896,500.00
Infraestructura Streamlit (6 meses)	L 97,500.00
Total probable	L 994,000.00

Fuente: Elaboración propia.

6.7.4 ESCENARIO PERT DEL PRESUPUESTO

En coherencia con la metodología de estimación de tres puntos empleada en el cronograma, el presupuesto incorpora explícitamente la incertidumbre mediante la técnica PERT (Program Evaluation and Review Technique). Se definen tres escenarios: optimista (O), que supone condiciones favorables de contratación y ausencia de imprevistos operativos; más probable (M), que corresponde a condiciones estándar del mercado; y pesimista (P), que contempla imprevistos

técnicos, ajustes en el alcance o variaciones en las tarifas de los perfiles requeridos. El costo esperado se obtiene mediante la expresión:

$$\text{Costo esperado} = (O + 4M + P) / 6 = (900,000 + 4 \times 941,000 + 1,000,000) / 6 = \text{L } 944,000.00$$

El escenario pesimista implica una desviación del +6.3% respecto al escenario más probable, mientras que el optimista supone una reducción del 4.3%. La amplitud limitada del rango (L 100,000) refleja que los principales componentes de costo los salarios de los perfiles especializados presentan baja volatilidad en el corto plazo, siempre que la contratación se realice conforme al cronograma definido.

TABLA 32 Escenario PERT del presupuesto reformulado

Escenario	Monto HNL	Base de estimación
Optimista (O)	L 940,000.00	-5.4% respecto al escenario más probable
Más probable (M)	L 994,000.00	RRHH + infraestructura.
Pesimista (P)	L 1,050,000.00	+5.6% respecto al escenario más probable
Costo estimado PERT	L 988,000.00	$(940,000 + 4 \times 994,000 + 1,050,000) / 6$

Fuente: Elaboración propia.

El costo esperado se calcula mediante la expresión $\text{Costo esperado} = (O + 4M + P) / 6$, lo cual produce un costo estimado PERT de L 988,000.00.

6.7.5 CÁLCULO DEL RETORNO DE LA INVERSIÓN

Dada la naturaleza institucional y no comercial de la propuesta, el retorno de la inversión (ROI) se interpreta como una medida de eficiencia pública y fortalecimiento de la capacidad analítica institucional, antes que como rentabilidad financiera directa. En este marco, los beneficios se desagregan en dos categorías cuantificables:

a) Ahorro en horas analíticas (L 149,760.00 anuales): Este rubro cuantifica el tiempo de análisis liberado por la automatización parcial del proceso de pronóstico del crédito. Bajo el supuesto de que el perfil DS tiene un costo mensual de L 45,000 (equivalente a L 259.6 por hora hábil, considerando una jornada estándar de 2,080 horas anuales), la adopción del sistema libera aproximadamente 577 horas anuales de trabajo analítico de alto valor, equivalentes a 11 horas por semana que el equipo puede reasignar a tareas de interpretación, validación y comunicación de resultados.

b) Beneficio operativo indirecto (L 329,760.00 anuales): Este componente estima el valor económico de la reducción de reprocesamiento de análisis, la mejora en la oportunidad de los reportes institucionales y la disminución de los costos de coordinación asociados a la obtención manual de datos. Aunque su cuantificación implica un mayor grado de estimación, su magnitud es consistente con benchmarks documentados en la literatura de sistemas de soporte a la decisión en instituciones de política económica.

TABLA 33 Análisis del retorno de la inversión reformulado

Concepto	Descripción y cálculo	Monto (HNL)
Inversión inicial	Costo esperado PERT con horizonte de 29 semanas	L 988,000.00
OPEX anual mantenimiento y soporte	15% × L 988,000 = L 148,200 Servidor + soporte técnico + actualizaciones	(L 148,200.00)
Ahorro en horas analíticas (beneficio directo)	577 HH/año × L 260.12/h (DS) = L 149,760 Automatización parcial: ≈ 11 HH/semanas liberadas	L 149,760.00
Beneficio operativo indirecto (sustentado)	(a) 416 HH reprocesamiento × L 289.02/h = L 120,231 (b) 120 HH coordinación reportes × L 289.02/h = L 34,682 (c) Reducción retrasos decisionales = L 174,847	L 329,760.00
Beneficio anual bruto	L 149,760 + L 329,760	L 479,520.00
Beneficio anual NETO (descontado OPEX)	L 479,520 – L 148,200	L 331,320.00
ROI NETO anual	(L 331,320 / L 988,000) × 100	33.54%
Período de recuperación NETO	L 988,000 / L 331,320	2.98 años
Escenario adverso: beneficio directo –20%	(L 119,808 + L 329,760) – L 148,200 = L 301,368	ROI: 30.50% · Rec.: 3.28 años

Fuente: Elaboración propia.

El ROI neto de 33.54% confirma la viabilidad financiera de la propuesta en el contexto de la función pública institucional. Por cada lempira invertido en el sistema, el BCH recupera L 0.34 en valor operativo anual neto, descontado el costo de mantenimiento. El beneficio neto anual de L 331,320 se sustenta en tres fuentes documentadas con cálculo de horas-hombre: automatización del proceso de pronóstico (577 HH/año), reducción de reprocesamiento analítico (416 HH/año) y eliminación de carga de coordinación de reportes (120 HH/año).

El período de recuperación neto de 2.98 años es coherente con el horizonte de evaluación de sistemas analíticos institucionales, donde la inversión se justifica por la mejora sostenida de la capacidad técnica y no por rentabilidad financiera inmediata. Bajo el escenario adverso en que el beneficio directo cae un 20% por ineficiencias en la adopción del personal, el ROI se mantiene en

30.50% y la recuperación en 3.28 años, lo que demuestra que la propuesta es financieramente robusta ante variaciones en los supuestos de beneficio.

6.7.6 IMPACTO CUANTITATIVO Y CUALITATIVO

Desde una perspectiva cuantitativa, la propuesta libera 577 horas anuales de trabajo analítico, reduce reprocesos y mejora la oportunidad de los reportes institucionales, con un beneficio operativo neto estimado en L 331,320 anuales y un ROI neto de 33.54%. El break-even se alcanza en el mes 36 desde la puesta en marcha.

Desde una perspectiva cualitativa, la propuesta fortalece la trazabilidad metodológica del análisis de crédito institucional, mejora la capacidad de monitoreo continuo, favorece la adopción gradual de herramientas analíticas avanzadas de bajo costo y refuerza la complementariedad entre técnicas predictivas y el juicio macroeconómico experto. En conjunto, estos elementos incrementan la viabilidad institucional de la propuesta y consolidan su utilidad como herramienta de apoyo a la función de análisis económico del Banco Central de Honduras.

Nota metodológica: Los costos de infraestructura corresponden a una estimación de implementación inicial bajo una arquitectura ligera con Streamlit y deberán ajustarse según el entorno tecnológico definitivo disponible en el Banco Central de Honduras.

6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

La presente sección verifica la alineación vertical de la tesis, demostrando que la propuesta del Capítulo VI constituye la respuesta lógica, coherente y directamente derivada del problema planteado en el Capítulo I, de las bases teóricas del Capítulo II, del diseño metodológico del Capítulo III y de las conclusiones y recomendaciones del Capítulo V.

La ilustración 43 representa la alineación que existe entre la propuesta y la tesis mediante una alineación vertical en dos niveles. El nivel superior muestra los cinco capítulos con secuencias conectadas y el nivel inferior los objetivos específicos con los objetivos de la propuesta que corresponden.

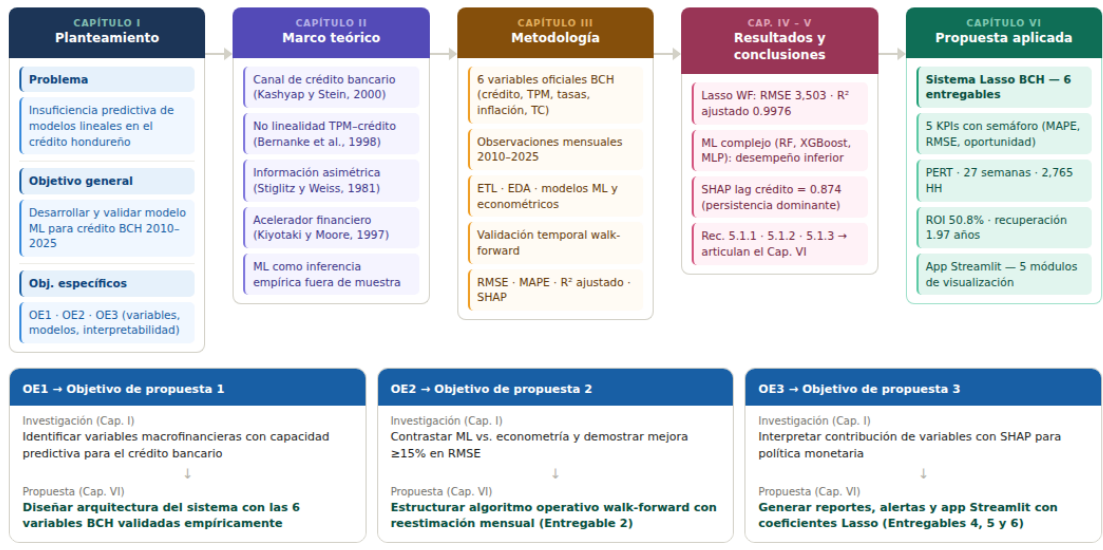


ILUSTRACIÓN 43 Alineación vertical de la investigación con la propuesta

Fuente: Elaboración propia

La Tabla 34 presenta la matriz de concordancia completa. Cada columna representa un componente estructural de la tesis, y cada fila un objetivo específico de la investigación con su correspondiente objetivo de la propuesta.

TABLA 34 Matriz de concordancia

Capítulo I			Capítulo II	Capítulo III		Capítulo V	Capítulo VI		
Título de la investigación	Objetivo general	Objetivo específico	Teoría y sustento (Cap. II)	Variables (Cap. III)	Población (Cap. III)	Técnica (Cap. III)	Conclusiones (Cap. V)	Título de la propuesta	Objetivos de la propuesta
Análisis comparativo de modelos de machine learning y econometría lineal para la predicción del crédito bancario hondureño basados en la tasa de política monetaria (2010–2025)	Desarrollar y validar un modelo de machine learning que obtenga un R^2 ajustado > 0.85 y/o RMSE $< 5\%$ en la predicción del crédito bancario agregado, utilizando datos macroeconómicos del BCH 2010–2025, para generar una herramienta predictiva robusta para la gestión de riesgo sistémico.	Identificar y preprocesar las variables macroeconómicas y financieras (TPM, inflación, tipo de cambio, tasas activa y pasiva) con capacidad informativa para el pronóstico del crédito, mediante análisis exploratorio y de correlación con datos oficiales del BCH.	Aprendizaje automático como inferencia empírica. Concibe el modelado predictivo como la estimación de una función que minimiza el error fuera de muestra sin imponer supuestos funcionales rígidos. Justifica el uso de ML para capturar patrones no lineales.	Crédito total sector privado (EMF-AMCC-01, ind. 549) TPM (EM-TPM-01, ind. 700) Tipo de cambio venta (EC-TCN-01, ind. 620) Tasa activa MN (EMF-TI-01, ind. 580)	Todas las observaciones mensuales del crédito bancario y variables macrofinancieras del BCH correspondientes al período 2010–2025.	Recolección y depuración de datos secundarios oficiales (API BCH). Análisis exploratorio y transformación de series de tiempo. Modelado econométrico de referencia (ARIMA, SARIMAX). Modelos de machine learning con validación temporal walk-forward. Evaluación del	La incorporación de variables macrofinancieras mejora el pronóstico frente a enfoques univariantes. Bajo validación temporal walk-forward, Lasso obtuvo el menor RMSE en nivel (3,503.77; R^2 ajustado 0.9976) y SARIMAX quedó muy cercano (RMSE 3,724.16). Los modelos complejos (RF,	Modelo de implementación de un sistema institucional de pronóstico dinámico y recurrente del crédito bancario agregado para el Banco Central de Honduras, basado en regresión lineal regularizada Lasso.	Garantizar la operación mensual continua, reproducible y auditable del sistema institucional de pronóstico dinámico y recurrente del crédito bancario agregado del Banco Central de Honduras, asegurando que cada ciclo de actualización genere pronósticos con $MAPE \leq 1.0\%$ y sean entregados dentro de los cinco días hábiles posteriores a

Capítulo I		Capítulo II	Capítulo III		Capítulo V	Capítulo VI			
Título de la investigación	Objetivo general	Objetivo específico	Teoría y sustento (Cap. II)	Variables (Cap. III)	Población (Cap. III)	Técnica (Cap. III)	Conclusiones (Cap. V)	Título de la propuesta	Objetivos de la propuesta
		Evaluar y contrastar el rendimiento de modelos de machine learning (Lasso, Random Forest, XGBoost, MLP) frente al benchmark econométrico tradicional, con la meta de alcanzar una mejora de al menos 15% en RMSE, para establecer la capacidad predictiva de las técnicas no lineales.	No linealidad en la transmisión monetaria. La relación TPM-crédito no es estable ni proporcional en el tiempo, invalidando supuestos lineales y reforzando la necesidad de enfoques regularizados y con validación temporal.	Tasa pasiva ahorro MN (EMF-TI-01, ind. 580)	Inflación interanual (EP-IPC-01, ind. 609)	desempeño predictivo fuera de muestra (RMSE, MAPE, R ²).	XGBoost, MLP) mostraron desempeño inferior o inestable: la mejora predictiva provino de la parsimonia, regularización y actualización secuencial. El análisis SHAP confirmó que la persistencia del crédito domina el pronóstico (importancia lag = 0.874), con aportes complementarios de tasas rezagadas y tipo de cambio.		la publicación de las series oficiales del BCH Ejecutar mensualmente el proceso de extracción, transformación y carga (ETL) de las seis variables macrofinancieras oficiales del BCH en menos de dos horas tras la publicación de las series, garantizando la integridad y consistencia de la base maestra del sistema. Reestimar y validar el modelo Lasso walk-forward

Capítulo I		Capítulo II	Capítulo III		Capítulo V	Capítulo VI			
Título de la investigación	Objetivo general	Objetivo específico	Teoría y sustento (Cap. II)	Variables (Cap. III)	Población (Cap. III)	Técnica (Cap. III)	Conclusiones (Cap. V)	Título de la propuesta	Objetivos de la propuesta
		Interpretar el impacto económico y la contribución de las variables predictivas en el mejor modelo de ML, mediante técnicas de interpretabilidad (SHAP), para traducir los resultados técnicos en recomendación							<p>en cada ciclo mensual, documentando el hiperparámetros λ seleccionado, las variables activas y el MAPE obtenido en la bitácora técnica del sistema.</p> <p>Generar y distribuir el reporte mensual de pronóstico dentro del plazo institucional definido, incluyendo el pronóstico puntual $t+1$, el intervalo de confianza al 95%, las métricas de</p>

Capítulo I		Capítulo II	Capítulo III		Capítulo V	Capítulo VI			
Título de la investigación	Objetivo general	Objetivo específico	Teoría y sustento (Cap. II)	Variables (Cap. III)	Población (Cap. III)	Técnica (Cap. III)	Conclusiones (Cap. V)	Título de la propuesta	Objetivos de la propuesta
		es de política monetaria y financiera.							<p>desempeño y las alertas del sistema.</p> <p>Activar el protocolo de recalibración extraordinaria cuando el MAPE supere el umbral amarillo (1.0%–2.5%) por dos ciclos consecutivos o el umbral rojo (>2.5%) en un ciclo.</p> <p>Mantener actualizada la aplicación Streamlit en cada ciclo, asegurando que los cinco módulos de visualización reflejen los datos y métricas del pronóstico</p>

Capítulo I		Capítulo II	Capítulo III		Capítulo V	Capítulo VI			
Título de la investigación	Objetivo general	Objetivo específico	Teoría y sustento (Cap. II)	Variables (Cap. III)	Población (Cap. III)	Técnica (Cap. III)	Conclusiones (Cap. V)	Título de la propuesta	Objetivos de la propuesta
									<p>más reciente dentro del mismo plazo de entrega del reporte.</p> <p>Implementación de protocolo de gobernanza para asegurar la integridad de la entrada de datos.</p>

Fuente: Elaboración propia.

REFERENCIAS BIBLIOGRÁFICAS

- Araujo, G. S., & Gaglianone, W. P. (2023). Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models. *Latin American Journal of Central Banking*, 4(2), 100087. <https://doi.org/10.1016/j.latcb.2023.100087>
- Auerbach, A. J., & Gorodnichenko, Y. (2012). Measuring the Output Responses to Fiscal Policy. *American Economic Journal: Economic Policy*, 4(2), 1–27. <https://doi.org/10.1257/pol.4.2.1>
- Avdjiev, S., & Zeng, Z. (2014). Credit growth, monetary policy and economic activity in a three-regime TVAR model. *Applied Economics*, 46(24), 2936–2951. <https://doi.org/10.1080/00036846.2014.916391>
- Balke, N. S. (2000). Credit and Economic Activity: Credit Regimes and Nonlinear Propagation of Shocks. *Review of Economics and Statistics*, 82(2), 344–349. <https://doi.org/10.1162/rest.2000.82.2.344>
- Banco Central de Costa Rica. (2024). Informe de política monetaria abril 2024. <https://www.bccr.fi.cr/publicaciones/DocPoliticaMonetariaInflacin/Documento-IPM-Abril-2024.pdf>
- Banco Central de Honduras. (2024a). Informe de estabilidad financiera, diciembre 2024 (Informe No. 27). <https://www.bch.hn/estadisticos/EF/LIBINFORME/IEF%20diciembre%202024.pdf>
- Banco Central de Honduras. (2024b). Memoria 2024 [Memoria Anual]. <https://www.bch.hn/estadisticos/GIE/LIBMemoria/Memoria%20Anual%202024.pdf>
- Banco Central de Honduras. (2025a). Análisis macroeconómico tasa de política monetaria. <https://www.bch.hn/politica-institucional/politica-monetaria/tasa-de-politica-monetaria>
- Banco Central de Honduras. (2025b, febrero 15). Términos y condiciones de la web-API. <https://www.bch.hn/marco-legal/terminos-y-condiciones-de-la-web-api/>

- Baya, S., Fadlallah, A., El Baraka, H., Bourouis, K., & Ezzraoui, M. (2025). Modeling and Forecasting the Real Effective Exchange Rate in Morocco: A Comparative Analysis by ARIMA, Random Forest and the Dynamic Factor Model. *Engineering Proceedings*, 112(1), 53. <https://doi.org/10.3390/engproc2025112053>
- Bernanke, B., Gertler, M., & Gilchrist, S. (1998). The Financial Accelerator in a Quantitative Business Cycle Framework (Working Paper No. 6455; Working Paper Series). National Bureau of Economic Research. <https://doi.org/10.3386/w6455>
- Berthold, M. R., Cebron, N., Dill, F., Gabriel, T. R., Kötter, T., Meinl, T., Ohl, P., Sieb, C., Thiel, K., & Wiswedel, B. (2008). KNIME: The Konstanz Information Miner. En C. Preisach, H. Burkhardt, L. Schmidt-Thieme, & R. Decker (Eds.), *Data Analysis, Machine Learning and Applications* (pp. 319–326). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-78246-9_38
- Bluwstein, K., Buckmann, M., Joseph, A., Kapadia, S., & Şimşek, Ö. (2021). Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach. Publications Office. <https://data.europa.eu/doi/10.2866/374576>
- Breiman, L. (2001a). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L. (2001b). Statistical Modeling: The Two Cultures. *Statistical Science*, 16(3), 199–215. <http://www.jstor.org/stable/2676681>
- Brelhoff, P. J., & Tarazi, A. M. (2010). Emisores no bancarios de dinero electronico: Enfoques de reglamentacion para proteger los fondos de los clientes (No. 56629). World Bank. <https://documents.worldbank.org/en/publication/documents-reports/documentdetail/365901468337465944>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>

- Chi, T.-C., Fan, T.-H., Ghigliazza, R. M., Giannone, D., & Wang, Z. (2025). Macroeconomic Forecasting and Machine Learning (arXiv:2510.11008). arXiv. <https://doi.org/10.48550/arXiv.2510.11008>
- Comisión Nacional de Bancos y Seguros. (2022). Circular C-003-2022: Norma para la evaluación y clasificación de la cartera crediticia. <https://circulares.cnbs.gob.hn/Archivo/Viewer/11/C003-2022.pdf>
- Comisión Nacional de Bancos y Seguros. (2024). Informe de estabilidad financiera cifras a septiembre 2024. [https://investigacioneinformes.cnbs.gob.hn/Cliente/Home/GetPdf?DocumentoId=76&ArchivoId=171&filename=Informe%20Estabilidad%20Financiera%20\(cifras%20septiembre%202024\).pdf](https://investigacioneinformes.cnbs.gob.hn/Cliente/Home/GetPdf?DocumentoId=76&ArchivoId=171&filename=Informe%20Estabilidad%20Financiera%20(cifras%20septiembre%202024).pdf)
- Congreso Nacional de Honduras. (2006). Ley de Transparencia y Acceso a la Información Pública y su Reglamento (Decreto Legislativo No. 170–2006). <https://www.tsc.gob.hn/biblioteca/index.php/leyes/17-ley-de-transparencia-y-acceso-a-la-informacion-publica>
- Coulombe, P. G., Leroux, M., Stevanovic, D., & Surprenant, S. (2020). How is Machine Learning Useful for Macroeconomic Forecasting? (arXiv:2008.12477). arXiv. <https://doi.org/10.48550/arXiv.2008.12477>
- Deb, P. (2023). Monetary Policy Transmission Heterogeneity: Cross-Country Evidence. IMF Working Papers, 2023(204), 1. <https://doi.org/10.5089/9798400257322.001>
- Demirgüç-Kunt, A., Klapper, L., Singer, D., & Ansar, S. (2022). The Global Findex Database 2021: Financial Inclusion, Digital Payments, and Resilience in the Age of COVID-19 [173780]. World Bank Group. <http://documents.worldbank.org/curated/en/099818107072234182>
- Diebold, F. X., & Mariano, R. S. (1995). Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*, 13(3), 253–263. <https://doi.org/10.1080/07350015.1995.10524599>

- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Giraldo, C., Giraldo, L., Gomez-Gonzalez, J. E., & Uribe, J. M. (2024). High frequency monitoring of credit creation: A new tool for central banks in emerging market economies. *The Quarterly Review of Economics and Finance*, 97, 101893. <https://doi.org/10.1016/j.qref.2024.101893>
- Giraldo, W. O., & Marín, V. J. (2021). Machine Learning para la estimación del riesgo de crédito en una cartera de consumo [EAFIT]. <https://hdl.handle.net/10784/29589>
- Greene, W. H. (2012). *Econometric analysis* (7th ed.). Prentice Hall.
- Gumata, N., & Ndou, E. (2017). *Bank Credit Extension and Real Economic Activity in South Africa*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-43551-0>
- Harrison, O., & Nguyen, V. (2025). How to Measure the Monetary Policy Stance. *IMF How To Notes*, 2025(003), 1. <https://doi.org/10.5089/9798400298882.061>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2006). *Metodología de la investigación* (4a. ed.). McGraw-Hill.
- Hernández Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.
- Hsu, C.-C., Chia, K.-C., & Chang, C.-Y. (2025). Basel III Finalising Post-Crisis Reforms: A Cross-Jurisdictional Assessment of Capital and Risk-Weighted Asset Frameworks and Their Implications for Financial Stability. SSRN. <https://doi.org/10.2139/ssrn.5719346>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts.

- International Monetary Fund. (2008). Normas Especiales para la Divulgación de Datos: Guía Para Suscriptores y Usuarios, 2007. <https://doi.org/10.5089/9781589065574.069>
- International Monetary Fund. (2011). The Policy Interest-Rate Pass-Through in Central America. IMF Working Papers, 11(240), 1. <https://doi.org/10.5089/9781463923228.001>
- International Monetary Fund. (2017). Monetary and Financial Statistics Manual and Compilation Guide. <https://doi.org/10.5089/9781513579191.069>
- International Monetary Fund. (2024). Colombia: Request for an Arrangement Under the Flexible Credit Line and Cancellation of the Current Arrangement-Press Release; Staff Report; Staff Supplement; and Statement by the Executive Director for Colombia. IMF Staff Country Reports, 2024(100). <https://doi.org/10.5089/9798400272868.002.A001>
- Kashyap, A. K., & Stein, J. C. (2000). What Do a Million Observations on Banks Say About the Transmission of Monetary Policy? *American Economic Review*, 90(3), 407–428. <https://doi.org/10.1257/aer.90.3.407>
- Kilian, L., & Lütkepohl, H. (2017). *Structural Vector Autoregressive Analysis: (1a ed.)*. Cambridge University Press. <https://doi.org/10.1017/9781108164818>
- Kiyotaki, N., & Moore, J. (1997). Credit Cycles. *Journal of Political Economy*, 105(2), 211–248. <https://doi.org/10.1086/262072>
- Ley Del Banco Central De Honduras, 34225 (2016). https://www.bch.hn/administrativas/JUR/Marco%20Legal%20OM%202/ley_bch.pdf
- Ley Del Sistema Financiero, 129–2004 (2004). [https://www.tsc.gob.hn/web/leyes/Ley%20del%20Sistema%20Financiero%20\(Reformado%20por%20el%20CPC\)2010.pdf](https://www.tsc.gob.hn/web/leyes/Ley%20del%20Sistema%20Financiero%20(Reformado%20por%20el%20CPC)2010.pdf)
- Li, Y., Li, L., Liu, Y., & Li, Q. (2022). MAHE-IM: Multiple Aggregation of Heterogeneous Relation Embedding for Influence Maximization on Heterogeneous Information Network. *Expert Systems with Applications*, 202, 117289. <https://doi.org/10.1016/j.eswa.2022.117289>

- Lundberg, S., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions (arXiv:1705.07874). arXiv. <https://doi.org/10.48550/arXiv.1705.07874>
- McKinney, W. (2022). Python for data analysis: Data wrangling with pandas, NumPy, and Jupyter (Third edition). O'Reilly.
- Mishkin, F. S. (2022). The economics of money, banking, and financial markets (Thirteenth edition). Pearson.
- Mishra, P., & Montiel, P. (2013). How effective is monetary transmission in low-income countries? A survey of the empirical evidence. *Economic Systems*, 37(2), 187–216. <https://doi.org/10.1016/j.ecosys.2012.12.001>
- Octavio, A., & Lopéz, O. (2024). Desarrollo de un modelo de machine learning de estimación de ingresos para el otorgamiento de crédito en instituciones financieras [UNIVERSIDAD DE CHILE]. <https://repositorio.uchile.cl/bitstream/handle/2250/202676/Desarrollo-de-un-modelo-de-machine-learning-de-estimacion-de-ingresos-para-el-otorgamiento-de-credito-en-instituciones-financieras.pdf?sequence=1&isAllowed=y>
- Ozgun, O., & Aslan, M. (2025). Monetary policy stance and foreign currency lending: Evidence from a persistently dollarized emerging market. *Economic Change and Restructuring*, 58(4), 52. <https://doi.org/10.1007/s10644-025-09895-y>
- Ozgun, O., Karagol, E. T., & Ozbugday, F. C. (2021). Machine learning approach to drivers of bank lending: Evidence from an emerging economy. *Financial Innovation*, 7(1), 20. <https://doi.org/10.1186/s40854-021-00237-1>
- Repullo, R., & Saurina, J. (2011). The Countercyclical Capital Buffer of Basel III: A Critical Assessment (Working Papers Wp2011_1102). CEMFI. https://ideas.repec.org/p/cmfi/wpaper/wp2011_1102.html
- Reserve Bank of India. (2024). Financial Stability Report. <https://rbidocs.rbi.org.in/rdocs/PublicationReport/Pdfs/FSR30122024F992B788790C44DCFBA4E8C9F98D912D9.PDF>

- Sadhwani, A., Giesecke, K., & Sirignano, J. (2021). Deep Learning for Mortgage Risk. *Journal of Financial Econometrics*, 19(2), 313–368. <https://doi.org/10.1093/jjfinec/nbaa025>
- Shmueli, G. (2010). To Explain or to Predict? *Statistical Science*, 25(3). <https://doi.org/10.1214/10-STS330>
- Smalter Hall, A. (2018). Machine Learning Approaches to Macroeconomic Forecasting. *The Federal Reserve Bank of Kansas City Economic Review*. <https://doi.org/10.18651/ER/4q18smalterhall>
- Stempień, D., & Ślepaczuk, R. (2025). Hybrid Models for Financial Forecasting: Combining Econometric, Machine Learning, and Deep Learning Models (arXiv:2505.19617). *arXiv*. <https://doi.org/10.48550/arXiv.2505.19617>
- Stiglitz, J. E., & Weiss, A. (1981). Credit Rationing in Markets with Imperfect Information. *The American Economic Review*, 71(3), 393–410. JSTOR.
- Stock, J. H., & Watson, M. (2012). Disentangling the Channels of the 2007-09 Recession. *Brookings Papers on Economic Activity*, 43(1 (Spring)), 81–156. <https://EconPapers.repec.org/RePEc:bin:bpeajo:v:43:y:2012:i:2012-01:p:81-156>
- Suri, T., & Jack, W. (2016). The long-run poverty and gender impacts of mobile money. *Science*, 354(6317), 1288–1292. <https://doi.org/10.1126/science.aah5309>
- World Bank. (2024). Glossary | DataBank. <https://databank.worldbank.org/metadataglossary/world-development-indicators/series/FD.AST.PRVT.GD.ZS>

ANEXOS