



**FACULTAD DE POSTGRADO
TRABAJO FINAL DE GRADUACIÓN**

**ANÁLISIS Y ESTIMACIÓN DE LA INFLACIÓN EN HONDURAS
MEDIANTE REDES NEURONALES ARTIFICIALES DE
MAYO 2005 A JUNIO 2024**

SUSTENTADO POR:

DANIELA ALEJANDRA BANEGAS SUAZO

PREVIA INVESTIDURA AL TÍTULO DE

**MÁSTER EN
ANALÍTICA DE NEGOCIOS**

TEGUCIGALPA, FRANCISCO MORAZÁN, HONDURAS, C.A.

ENERO, 2025

**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA
UNITEC**

FACULTAD DE POSTGRADO

AUTORIDADES UNIVERSITARIAS

**PRESIDENTE EJECUTIVO /
RECTORA**

ROSALPINA RODRÍGUEZ

**SECRETARIO GENERAL /
PRORRECTOR**

ROGER MARTÍNEZ MIRALDA

**VICERRECTOR ACADÉMICO NACIONAL
JAVIER ABRAHAM SALGADO LEZAMA**

**DECANA DE POSTGRADO
ANA DEL CARMEN RETTALLY VARGAS**

**ANÁLISIS Y ESTIMACIÓN DE LA INFLACIÓN EN HONDURAS
MEDIANTE REDES NEURONALES ARTIFICIALES DE
MAYO 2005 A JUNIO 2024**

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

ASESOR METODOLÓGICO

JOSÉ RODOLFO SORTO BUESO

ASESOR TEMÁTICO

BAYRON BARAHONA ALVAREZ

MIEMBROS DE LA TERNA:

MARIO ALBERTO GALLO SANDOVAL

JESÚS RICARDO RODRÍGUEZ

GERARDO LUJANO

DERECHOS DE AUTOR

© Copyright 2025
Daniela Alejandra Banegas Suazo

Todos los derechos son reservados.



FACULTAD DE POSTGRADO

ANÁLISIS Y ESTIMACIÓN DE LA INFLACIÓN EN HONDURAS MEDIANTE REDES NEURONALES ARTIFICIALES DE MAYO 2005 A JUNIO 2024

DANIELA ALEJANDRA BANEGAS SUAZO

Resumen

Esta investigación tiene como objetivo desarrollar una propuesta de modelo basado en redes neuronales para predecir la inflación mensual en Honduras, con el fin de mejorar la precisión de las proyecciones económicas del país. El estudio se centró en identificar los factores clave, tanto macroeconómicos como microeconómicos, que influyen en la inflación y en evaluar el rendimiento del modelo propuesto. Para ello, se adoptó un enfoque cuantitativo, utilizando datos históricos y técnicas avanzadas de inteligencia artificial para analizar la compleja interacción de las variables involucradas. Los resultados obtenidos mostraron que el modelo de redes neuronales logró una precisión significativa en las predicciones, superando los métodos tradicionales utilizados hasta el momento. En conclusión, se recomienda la implementación de este modelo en las políticas económicas del país, dada su capacidad para gestionar de manera más eficiente la dinámica inflacionaria y proporcionar pronósticos más robustos y adaptados a la realidad económica hondureña.

Palabras claves: (análisis, inteligencia artificial, inflación, modelos, redes neuronales)



GRADUATE SCHOOL

**ANÁLISIS Y ESTIMACIÓN DE LA INFLACIÓN EN
HONDURAS MEDIANTE REDES NEURONALES**

DANIELA ALEJANDRA BANEGAS SUAZO

Abstract

This research aims to develop a proposal for a neural network-based model to predict monthly inflation in Honduras, with the goal of improving the accuracy of the country's economic projections. The study focused on identifying key macroeconomic and microeconomic factors influencing inflation and evaluating the performance of the proposed model. A quantitative approach was adopted, using historical data and advanced artificial intelligence techniques to analyze the complex interaction of the involved variables. The results showed that the neural network model achieved significant accuracy in predictions, surpassing the traditional methods used so far. In conclusion, the implementation of this model in the country's economic policies is recommended, given its ability to more efficiently manage inflation dynamics and provide more robust forecasts adapted to the economic reality of Honduras.

Keywords: (analysis, artificial intelligence, inflation, models, neural networks)

DEDICATORIA

Primeramente, agradezco a Dios, quien ha sido mi guía en cada paso de este camino. Su gracia me ha dado la fuerza para enfrentar cada desafío y continuar con confianza y esperanza. A mi madre, Elizabeth Suazo, por su amor incondicional y su apoyo constante. Gracias por enseñarme a creer en mí misma, a mantener la fe y a nunca rendirme, aun en los momentos más difíciles. Este logro es un reflejo de tu dedicación y cariño, y lo celebro contigo con todo mi corazón, reconociendo que sin ti nada de esto hubiera sido posible. Agradezco profundamente tus sacrificios, que han sido mi inspiración para alcanzar esta meta.

AGRADECIMIENTO

Agradezco a Dios por guiarme en cada paso de este camino y brindarme la fortaleza necesaria para superar los desafíos. Su presencia ha sido una constante fuente de inspiración y esperanza en mi vida. También extiendo mi más profundo agradecimiento a mi asesor, José Rodolfo Sorto Bueso, por su invaluable apoyo, paciencia y dedicación, que me motivaron a dar lo mejor de mí en cada etapa de este proyecto. Igualmente, quiero expresar mi gratitud a todos los docentes de UNITEC, quienes me brindaron la oportunidad de formarme en un entorno académico de excelencia. Cada día fue una experiencia de crecimiento y aprendizaje, donde su dedicación y compromiso se hicieron evidentes. Gracias a sus enseñanzas, he podido desarrollar no solo conocimientos, sino también valores fundamentales. Su entrega y pasión por la enseñanza han sido un ejemplo inspirador, y este logro es, en gran parte, reflejo de su esfuerzo por formar profesionales integrales y comprometidos.

ÍNDICE DE CONTENIDO

DEDICATORIA.....	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDO	vi
ÍNDICE DE TABLAS.....	xi
ÍNDICE DE FIGURAS	xii
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN.....	1
1.1 INTRODUCCIÓN	1
1.2 ANTECEDENTES DEL PROBLEMA.....	2
1.3 DEFINICIÓN DEL PROBLEMA	4
1.3.1 ENUNCIADO DEL PROBLEMA.....	4
1.3.2 FORMULACIÓN DEL PROBLEMA	5
1.3.3 PREGUNTAS DE INVESTIGACIÓN	5
1.4 OBJETIVOS DEL PROYECTO	5
1.4.1 OBJETIVO GENERAL	5
1.4.2 OBJETIVOS ESPECÍFICOS	6
1.5 JUSTIFICACIÓN	6
CAPÍTULO II. MARCO TEÓRICO.....	8
2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL.....	8
2.1.1 ANÁLISIS DEL MACROENTORNO	8
2.1.1.1 ANÁLISIS INFLACIONARIO A NIVEL MUNDIAL	8
2.1.1.2 ANÁLISIS INFLACIONARIO EN ESPAÑA	9
2.1.1.3 ANÁLISIS INFLACIONARIO EN ESTADOS UNIDOS.....	11
2.1.1.4 REDES NEURONALES EN ESPAÑA.....	12
2.1.1.5 REDES NEURONALES EN INDONESIA	12
2.1.2 ANÁLISIS DEL MICROENTORNO	13
2.1.2.1 ANÁLISIS INFLACIONARIO A NIVEL AMÉRICA LATINA Y EL CARIBE	13
2.1.2.2 ANÁLISIS INFLACIONARIO EN PARAGUAY.....	14

2.1.2.3	ANÁLISIS INFLACIONARIO EN ARGENTINA.....	15
2.1.2.4	ANÁLISIS INFLACIONARIO EN CENTROAMÉRICA	16
2.1.2.5	ANÁLISIS INFLACIONARIO EN CENTROAMÉRICA Y REPÚBLICA DOMINICANA.....	17
2.1.2.6	REDES NEURONALES A NIVEL AMÉRICA LATINA Y EL CARIBE	18
2.1.3	ANÁLISIS INTERNO	19
2.1.3.1	ANÁLISIS INFLACIONARIO EN HONDURAS.....	19
2.1.3.2	ENFOQUES Y TÉCNICAS DE MODELADO EN HONDURAS.....	21
2.2	CONCEPTUALIZACIÓN.....	22
2.2.1	VARIABLE DEPENDIENTE.....	22
2.2.1.1	INFLACIÓN	22
2.2.2	VARIABLES INDEPENDIENTES.....	23
2.2.2.1	SECTOR MONETARIO/FINANCIERO	23
2.2.2.2	SECTOR EXTERNO/COMERCIAL	23
2.2.2.3	ACTIVIDAD ECONÓMICA	24
2.2.3	VARIABLES MACROECÓNOMICAS	24
2.2.4	VARIABLES MICROECONÓMICAS	25
2.2.5	OTRAS CONCEPTUALIZACIONES	25
2.2.5.1	MACHINE LEARNING.....	25
2.2.5.2	APRENDIZAJE SUPERVISADO.....	25
2.2.5.3	APRENDIZAJE PROFUNDO.....	26
2.2.5.4	RED NEURONAL ARTIFICIAL.....	26
2.2.5.5	SERIES DE TIEMPO	27
2.2.5.6	MINERÍA DE DATOS	27
2.3	TEORÍAS DE SUSTENTO.....	28
2.3.1	BASES TEÓRICAS	28
2.3.1.1	TEORÍA ECONÓMICA.....	28
2.3.1.2	TEORÍA DE POLÍTICA MONETARIA.....	30
2.3.1.3	TEORÍA DE ANALÍTICA PREDICTIVA	32
2.3.2	METODOLOGÍAS DESARROLLADAS POR OTROS	

INVESTIGADORES	35
2.3.2.1 REGRESIÓN LINEAL	35
2.3.2.2 MODELOS ARIMA	35
2.3.2.3 MODELOS DE VECTORES AUTORREGRESIVOS	36
2.3.2.4 REDES NEURONALES ARTIFICIALES	36
2.3.3 INSTRUMENTOS UTILIZADOS	37
2.4 . MARCO LEGAL	38
CAPÍTULO III. METODOLOGÍA	41
3.1 CONGRUENCIA METODOLÓGICA	41
3.1.1 MATRIZ METODOLÓGICA	41
3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO	44
3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES	45
3.1.4 HIPÓTESIS	47
3.2 ENFOQUE Y MÉTODOS	48
3.2.1 ENFOQUE	48
3.2.2 ALCANCE	49
3.2.3 DISEÑO	49
3.2.4 MÉTODO	49
3.2.5 INSTRUMENTOS	49
3.3 DISEÑO DE LA INVESTIGACIÓN	50
3.3.1 POBLACIÓN	50
3.3.2 MUESTRA	51
3.3.3 TÉCNICAS DE MUESTREO	51
3.4 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS	51
3.4.1 TÉCNICAS	51
3.4.1.1 MINERÍA DE DATOS	52
3.4.1.2 MODELOS PREDICTIVOS	52
3.4.2 INSTRUMENTOS	52
3.4.2.1 MICROSOFT EXCEL	52
3.4.2.2 PYTHON	52
3.4.3 PROCEDIMIENTOS	52

3.5	FUENTES DE INFORMACIÓN	53
3.5.1	FUENTES PRIMARIAS	53
3.5.2	FUENTES SECUNDARIAS.....	54
CAPÍTULO IV. RESULTADOS Y ANÁLISIS		55
4.1	INFORME DE PROCESO DE RECOLECCIÓN DE DATOS	55
4.2	RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS	58
4.2.1	FACTORES CLAVE QUE IMPULSAN LA INFLACIÓN EN HONDURAS 58	
4.2.1.1	ESTADÍSTICOS DESCRIPTIVOS DE LA INFLACIÓN	58
4.2.1.2	DISTRIBUCIÓN Y ESTACIONALIDAD DE LA INFLACIÓN	59
4.2.1.3	ANÁLISIS DE LA RELACIÓN ENTRE LAS VARIABLES INDEPENDIENTES Y LA INFLACIÓN.....	62
4.2.2	MODELOS PARA PRONOSTICAR LA INFLACIÓN EN HONDURAS ..	73
4.2.2.1	REDES NEURONALES.....	73
4.2.2.2	MODELO SARIMA	77
4.3	OTROS RESULTADOS	79
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES		82
5.1.	CONCLUSIONES	82
5.2.	RECOMENDACIONES.....	83
CAPÍTULO VI. APLICABILIDAD		85
6.1	NOMBRE DE LA PROPUESTA.....	85
6.2	JUSTIFICACIÓN DE LA PROPUESTA.....	85
6.3	ALCANCE DE LA PROPUESTA	85
6.3.1	OBJETIVO GENERAL DEL PROYECTO.....	85
6.3.2	OBJETIVOS ESPECÍFICOS DEL PROYECTO	86
6.4	FUENTES DE DATOS Y PROCESAMIENTO.....	86
6.4.1	FUENTES DE DATOS	86
6.4.2	CONJUNTO DE DATOS	88
6.4.3	IMPORTACIÓN DE LIBRERÍAS	89
6.4.4	LECTURA DE DATOS	89
6.4.5	PROCESAMIENTO DE DATOS	89

6.5	DISEÑO E IMPLEMENTACIÓN DEL MODELO	90
6.5.1	DIVISION DE LOS DATOS	90
6.5.2	ESTRUCTURA DEL MODELO	90
6.5.3	PREDICCIÓN Y EVALUACIÓN DEL MODELO	91
6.5.4	PREDICCIONES FUTURAS DEL MODELO	92
6.6	DESPLIEGUE O AUTOMATIZACIÓN DEL SISTEMA	93
6.7	CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO.....	94
6.7.1	PRESUPUESTO DEL PROYECTO.....	94
6.7.2	CRONOGRAMA DE IMPLEMENTACIÓN	95
6.7.2.1.	METODOLOGÍA DE ESTIMACIÓN DEL TIEMPO.....	96
6.7.2.2.	CRONOGRAMA POR FASES	97
6.8	CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA.....	99
	REFERENCIAS BIBLIOGRÁFICAS	103
	Referencias	103
	ANEXOS	108
	Anexo 1	108
	Anexo 2	109
	Anexo 3	110
	Anexo 4	110
	Anexo 5	111

ÍNDICE DE TABLAS

Tabla 1. Matriz de congruencia metodológica.....	42
Tabla 2. Operacionalización de variable dependiente.....	45
Tabla 3. Operacionalización de variables independientes.....	45
Tabla 4. Diccionario de variables.....	88
Tabla 5. Detalles del presupuesto.....	95
Tabla 6. Resumen de las fases.....	98
Tabla 7. Cronograma de implementación.....	98
Tabla 8. Matriz de Concordancia.....	99

ÍNDICE DE FIGURAS

Figura 1. Tasa de inflación a nivel Mundial de 2010 a 2029	9
Figura 2. Inflación en el área del euro y contribución de los componentes	10
Figura 3. Evolución anual del IPC en España	10
Figura 4. Tasa de inflación anual es Estados Unidos	11
Figura 5. Ranking de los 15 Países de América Latina y el Caribe con las Tasa de Inflación más altas en 2024.....	14
Figura 6. Tasa de inflación en Paraguay	15
Figura 7. Evolución anual de la tasa de inflación en Argentina desde 2017 hasta 2025	16
Figura 8. Tasa de inflación interanual	17
Figura 9. Contribución de las divisiones a la inflación interanual	18
Figura 10. Aporte de la Inflación Interanual por Rubros.....	20
Figura 11. Minería de datos	28
Figura 12. Diagrama de variables.....	44
Figura 13. Enfoque y Métodos	48
Figura 14. Recolección de datos.....	57
Figura 15. Datos	57
Figura 16. Comportamiento del IPC Variación Interanual	59
Figura 17. Distribución del IPC Variación Interanual.....	60
Figura 18. Estacional de la serie IPC Variación Interanual	61
Figura 19. Diferenciado IPC Variación Interanual	62
Figura 20. Matriz de Correlación.....	64
Figura 21. Matriz de Correlación Limpia	66
Figura 22. Distribución variables Exógenas o Independientes.....	68
Figura 23. IPC y TPM.....	69
Figura 24. IPC y TA.....	70
Figura 25. IPC e IMAE VARIACION INTERANUAL.....	71
Figura 26. IPC y Tipo de Cambio.....	71
Figura 27. IPC E importaciones Netas	72
Figura 28. IPC y M2 Agregado Monetario	72
Figura 29. IPC y Consumo Hogares.....	73
Figura 30. Red Neuronal IPC con Variables Exógenas.....	76
Figura 31. Modelo SARIMA IPC	79
Figura 32. Comparación Valores Reales y Predichos en todo el Conjunto	81
Figura 33. Serie IPC.....	86
Figura 34. Serie Tipo de Cambio.....	87
Figura 35. Serie Exportaciones Netas.....	87
Figura 36. Serie Agregado Monetario M2.....	88
Figura 37. Librerías	89
Figura 38. Lectura de datos.....	89
Figura 39. Procesamiento de los datos	90
Figura 40. División de los datos.....	90
Figura 41. Estructura de la red neuronal artificial.....	91
Figura 42. predicción y evaluación del modelo.....	92
Figura 43. Predicciones Futuras	92
Figura 44. Ejecutable	93

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

Este capítulo establece la estructura de la investigación, abordando el problema y los antecedentes del tema a analizar. Se presentan las preguntas de investigación y los objetivos, tanto generales como específicos, que orientarán el desarrollo del estudio. Además, se incluye la justificación del problema, resaltando la importancia y pertinencia del proyecto en el contexto actual.

1.1 INTRODUCCIÓN

La inflación es un fenómeno económico crucial que afecta profundamente el poder adquisitivo de los ciudadanos, la competitividad de las empresas y la estabilidad financiera de un país. Comprender y predecir con precisión la inflación es fundamental para formular políticas económicas que promuevan la estabilidad, especialmente en contextos donde las condiciones son cambiantes, como en Honduras, que ha atravesado retos económicos considerables en tiempos recientes.

El propósito de este estudio es desarrollar un modelo basado en redes neuronales artificiales que estime de manera precisa la inflación mensual en Honduras. Esta estrategia se centra en identificar los factores macroeconómicos y microeconómicos más influyentes en la dinámica inflacionaria, ofreciendo herramientas predictivas que mejoren las capacidades de gestión económica. La motivación para abordar este tema surge de la necesidad de contar con modelos de predicción más robustos que superen las limitaciones de los enfoques tradicionales.

Se aspira a que esta investigación, centrada en el análisis de la inflación desde los determinantes clave, proporcione herramientas predictivas más precisas que contribuyan a la estabilidad financiera del país. A través de la identificación de estos factores, el estudio busca ofrecer soluciones innovadoras para enfrentar los desafíos inflacionarios y mejorar la gestión de riesgos económicos. Asimismo, se anticipa que los resultados de este estudio sean valiosos para las instituciones gubernamentales de Honduras, al facilitar una comprensión más profunda de la inflación y sus factores determinantes en el entorno hondureño.

1.2 ANTECEDENTES DEL PROBLEMA

Desde finales del siglo XX hasta la actualidad, Honduras ha enfrentado importantes fluctuaciones en su panorama económico, con la inflación como uno de los aspectos más destacados. Durante este período, una combinación de factores internacionales y locales ha moldeado la economía del país, generando un entorno complejo y lleno de desafíos.

En 1999, Honduras enfrentó presiones inflacionarias, con una tasa del Índice de Precios al Consumidor (IPC) alcanzando el 11.65%. Este aumento fue atribuido en parte al alza en los precios internacionales del petróleo, así como a los ajustes salariales implementados a nivel nacional. Sin embargo, las políticas macroeconómicas adoptadas durante este período lograron reducir la tasa de crecimiento de la inflación, marcando un descenso al 10.1% en el año 2000. Estas medidas resaltan la importancia de una gestión económica efectiva para controlar y mitigar los efectos inflacionarios (SEFIN, 2000).

Honduras experimentó una moderación en las tasas de inflación, a pesar de registrar cifras significativas, como el 10.8% en el año 2008, la tasa de inflación se mantuvo dentro de las metas propuestas por el Banco Central de Honduras. Esta estabilidad reflejó una tendencia hacia una inflación más controlada, facilitada por políticas económicas más efectivas y una mayor estabilidad macroeconómica (UNAH, 2022).

Sin embargo, a principios de 2022, Honduras se enfrentó a un aumento repentino en la inflación. Durante el primer trimestre, la tasa de inflación alcanzó un preocupante 6.37%, representando un incremento del 2.27% respecto a años anteriores. Este aumento se atribuyó principalmente al alza en los precios del petróleo y los alimentos, factores que también afectaron a otras economías emergentes y en desarrollo a nivel mundial (COHEP, 2022).

A lo largo de 2023 y principios de 2024, la economía global se encontraba en proceso de recuperación tras los embates de la pandemia de COVID-19 y los conflictos internacionales, como la disputa entre Rusia y Ucrania. Aunque se observó una desaceleración en la tasa de inflación, descendiendo al 4.8% en 2024, persistieron desafíos significativos. El aumento en los precios de las materias primas y otros factores exógenos mantuvieron la presión sobre la economía hondureña y la región latinoamericana en general (FMI, 2023).

Para comprender mejor el fenómeno de la inflación y su dinámica, es fundamental revisar los hallazgos más relevantes que se han obtenido, así como el uso de modelos avanzados, como las redes neuronales, para mejorar las predicciones en este ámbito.

La tesis "Utilización de Redes Neuronales Artificiales (RNA) como alternativa para el pronóstico del Índice de Precios al Consumidor (IPC) y contraste de resultados con modelos estadísticos tradicionales (ARIMA y VAR) para el Ecuador periodo 2000-2017" aborda la necesidad de optimizar los métodos de predicción económica, centrada en el IPC, un indicador clave para la política económica. En un contexto de avances tecnológicos, destaca la relevancia de las RNA. El estudio señala que el IPC afecta tanto la economía como la vida cotidiana, justificando métodos más precisos. Teóricamente, enriquece la literatura económica al integrar metodologías innovadoras, mientras que, en la práctica, sus hallazgos podrían influir en políticas económicas. Según los resultados, el modelo SARIMA supera a ARIMA y VAR, y enfatiza la importancia de la topología de la red y el tratamiento de variables en el desempeño de las RNA (Mora, 2018).

El artículo "Pronóstico de la Inflación Utilizando Métodos de Aprendizaje Automático en Rusia" aborda la necesidad de mejorar la precisión en las predicciones de inflación, especialmente en el marco de la política de metas de inflación adoptada por el Banco de Rusia en diciembre de 2014. Este estudio responde a la limitada eficacia de los modelos econométricos tradicionales, cuyo desempeño afecta la estabilidad económica y la política monetaria. Teóricamente, aporta a la literatura al incorporar técnicas de aprendizaje automático en el análisis de variables macroeconómicas, un campo poco explorado en Rusia. En términos prácticos, demuestra que estos métodos superan a los modelos tradicionales, mejorando la calidad de los pronósticos y apoyando decisiones más informadas en política monetaria (Baybuza, 2018).

El artículo "Predicción de la Tasa de Inflación Basada en el Algoritmo de Red Neuronal de Retropropagación" aborda la necesidad de métodos más avanzados y precisos para prever la inflación, un aspecto crucial para la estabilidad económica y la política monetaria. Centrado en la región de Samarinda, East Kalimantan, el estudio utiliza el algoritmo de Red Neuronal de Retropropagación (BPNN) como herramienta para mejorar la precisión de los pronósticos. El trabajo destaca la importancia de aplicar tecnologías

modernas al análisis económico local, ofreciendo una contribución teórica significativa al incorporar aprendizaje profundo en este campo. En la práctica, sus resultados tienen el potencial de optimizar la formulación de políticas y fortalecer la economía regional (Purnawansyah et al., 2019).

La tesis "Pronóstico de la Inflación en Perú utilizando Redes Neuronales Recurrentes y Modelos ARIMA" explora herramientas avanzadas para predecir la inflación en un contexto de incertidumbre política y fluctuaciones económicas en Perú. La investigación compara los modelos ARIMA y redes neuronales recurrentes, destacando la superioridad de las Long Short-Term Memory (LSTM) para analizar datos secuenciales en escenarios no estacionarios. Los resultados evidencian que el modelo LSTM proporciona pronósticos más precisos, lo que subraya su utilidad en la formulación de políticas económicas efectivas y en la gestión financiera. Asimismo, este estudio refuerza la importancia de aplicar técnicas de aprendizaje automático para optimizar el análisis económico y enriquecer la literatura en econometría (Chilón Ayay, 2023).

1.3 DEFINICIÓN DEL PROBLEMA

1.3.1 ENUNCIADO DEL PROBLEMA

La inflación en Honduras es un fenómeno complejo y multifacético que impacta directamente en el bienestar económico del país. Afecta no solo el poder adquisitivo de los ciudadanos, reduciendo su capacidad para adquirir bienes y servicios, sino que también influye en la competitividad de las empresas y en la estabilidad financiera general. A pesar de los esfuerzos de los organismos económicos y financieros por gestionar y mitigar sus efectos, la inflación sigue siendo un desafío significativo. Comprender sus causas, dinámicas y variabilidad es crucial para formular políticas públicas más efectivas y proteger la economía de fluctuaciones adversas.

Sin embargo, los enfoques tradicionales para pronosticar la inflación suelen ser limitados, ya que se basan en relaciones lineales entre variables y no siempre logran captar la complejidad inherente a los factores que la impulsan. Por tanto, surge la necesidad de explorar métodos más avanzados, como los modelos de redes neuronales, que puedan manejar mejor esta no linealidad y proporcionar predicciones más precisas.

1.3.2 FORMULACIÓN DEL PROBLEMA

En Honduras, la inflación tiene un impacto significativo en el poder adquisitivo de los ciudadanos y en la estabilidad económica general. Sin embargo, los métodos tradicionales empleados para predecir este fenómeno han revelado limitaciones, especialmente en su capacidad para captar la complejidad y la no linealidad de los factores macroeconómicos y microeconómicos que lo influyen. A pesar de la disponibilidad de datos y estudios previos sobre la inflación, la adopción de modelos avanzados que reflejen adecuadamente la dinámica no lineal de estos factores podría agregar un valor considerable al proceso de predicción. Por lo tanto, es fundamental explorar nuevas metodologías que proporcionen pronósticos más precisos y alineados con la realidad económica del país.

Esto plantea la siguiente pregunta: ¿Cómo se puede desarrollar la propuesta de un modelo basado en redes neuronales que permita predecir la inflación mensual de manera más robusta y precisa, considerando la interacción no lineal de las variables macroeconómicas y microeconómicas clave?

1.3.3 PREGUNTAS DE INVESTIGACIÓN

1. ¿Cuáles son los factores clave que impulsan la inflación en Honduras?
2. ¿Qué precisión pueden alcanzar los modelos de redes neuronales en la predicción de la inflación mensual en Honduras?
3. ¿Cómo se pueden optimizar las redes neuronales para maximizar su rendimiento en la predicción de la inflación mensual?
4. ¿Es posible elaborar una propuesta para la implementación de un algoritmo basado en redes neuronales para predecir la inflación en Honduras?

1.4 OBJETIVOS DEL PROYECTO

1.4.1 OBJETIVO GENERAL

Desarrollar la propuesta de un modelo basado en redes neuronales para predecir la inflación mensual en Honduras, analizando los factores macroeconómicos y microeconómicos que influyen en este fenómeno, con el fin de proporcionar pronósticos más precisos y útiles para la toma de decisiones económicas.

1.4.2 OBJETIVOS ESPECÍFICOS

1. Identificar y analizar los factores clave que impulsan la inflación en Honduras, considerando tanto variables macroeconómicas como microeconómicas, para comprender su impacto en el fenómeno inflacionario.
2. Evaluar la precisión de los modelos de redes neuronales en la predicción de la inflación mensual en Honduras, mediante la comparación de sus resultados con los de modelos tradicionales de pronóstico.
3. Optimizar las redes neuronales para maximizar su rendimiento en la predicción de la inflación mensual, identificando las configuraciones y técnicas que mejoren su capacidad de captar la interacción no lineal de las variables involucradas.
4. Elaborar una propuesta para la implementación de un algoritmo de redes neuronales que permita la predicción de la inflación en Honduras, evaluando su viabilidad y el impacto potencial en la precisión de los pronósticos económicos del país.

1.5 JUSTIFICACIÓN

La inflación en Honduras es un fenómeno de gran importancia económica que requiere un análisis profundo para entender sus determinantes y tendencias. Este estudio es necesario porque la inflación impacta no solo la estabilidad financiera del país, sino también la calidad de vida de sus ciudadanos. La necesidad de información precisa y oportuna sobre la inflación es crucial para que las autoridades económicas y gubernamentales puedan diseñar estrategias y políticas adecuadas que fomenten un crecimiento económico sostenible y equitativo.

La investigación se centra en desarrollar una propuesta de un modelo basado en redes neuronales para mejorar la precisión de las predicciones inflacionarias en Honduras, esto es especialmente relevante en un contexto donde los métodos tradicionales de pronóstico han demostrado ser insuficientes para captar la complejidad y la no linealidad de los factores macroeconómicos y microeconómicos que influyen en la inflación. La incorporación de técnicas de inteligencia artificial en este análisis representa una oportunidad para obtener pronósticos más precisos y adaptados a las condiciones locales.

Desde la perspectiva económica, este estudio permitirá a los responsables de formular políticas públicas contar con herramientas más efectivas para anticipar tendencias inflacionarias, lo que facilitará la implementación de medidas que mitiguen los efectos adversos de la inflación. Desde un enfoque financiero, mejorará la toma de decisiones en inversiones y planificación presupuestaria por parte de empresas y entidades gubernamentales. Además, esta investigación es valiosa porque contribuye a la comprensión de los factores que impulsan la inflación en Honduras, lo que puede enriquecer los debates sobre políticas y estrategias en foros económicos. Al examinar tanto los factores internos como los externos que inciden en la inflación, este estudio ofrecerá una perspectiva integral que facilitará una gestión más efectiva de las dinámicas económicas del país.

CAPÍTULO II. MARCO TEÓRICO

Este capítulo aborda las fuentes de información más significativas que se han examinado en relación con la investigación. Se presentan aportes teóricos, técnicos y datos estadísticos relevantes a nivel internacional que respaldan el problema planteado y las variables de estudio. A través de esta revisión, se busca establecer un fundamento sólido que permita comprender la complejidad del fenómeno analizado y la necesidad de abordarlo desde una perspectiva académica y práctica.

2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL.

Esta sección examina la inflación en tres niveles: global, regional, y nacional. A nivel macro, se abordan factores internacionales que impactan la economía mundial. En el microentorno, se analiza la inflación en América Latina y el Caribe, mientras que, en el análisis interno, se detalla la situación en Honduras. Además, se incluyen estudios de redes neuronales aplicados para identificar patrones y predecir la inflación, explorando cómo esta herramienta permite comprender la dinámica inflacionaria en cada nivel económico.

2.1.1 ANÁLISIS DEL MACROENTORNO

En este apartado se examina el contexto económico global y las principales tendencias inflacionarias a nivel mundial. A partir de fenómenos como la pandemia y las tensiones geopolíticas, se analizará cómo estos factores han influido en los precios y en el crecimiento económico de diversas regiones, impactando la estabilidad financiera de los países. Asimismo, se presentan estudios en los cuales se han utilizado redes neuronales para abordar esta problemática, explorando su aplicabilidad en la identificación de patrones y en la predicción de la inflación en un entorno global complejo y en constante cambio.

2.1.1.1 ANÁLISIS INFLACIONARIO A NIVEL MUNDIAL

Según el Fondo Monetario Internacional (2024), la perspectiva sobre la evolución de la inflación global es moderadamente optimista, destacando un proceso de desaceleración que, no obstante, se mantiene en niveles relativamente altos. Se proyecta que la inflación global disminuirá a un 3.5% hacia finales del próximo año, por debajo del promedio observado en las dos décadas previas a la pandemia de COVID-19, esta proyección sugiere una desinflación sostenida que ha evitado una recesión mundial. La moderación de la

inflación se atribuye a factores derivados de recientes choques de oferta y demanda, como la pandemia y el conflicto en Ucrania. En este contexto, la política monetaria ha sido crucial para estabilizar las expectativas de inflación, evitando efectos de segunda ronda que podrían haber desencadenado una espiral de precios y salarios.




Figura 1. Tasa de inflación a nivel Mundial de 2010 a 2029

Fuente: (Statista, 2024c)

En la Figura 1 se observa que el año 2022 cerró con la tasa de inflación más elevada de la última década, según el indicador adelantado del Fondo Monetario Internacional. Este organismo también ajustó a la baja sus proyecciones sobre el crecimiento del PIB mundial, reflejando un panorama menos optimista de lo esperado. La guerra entre Rusia y Ucrania ha intensificado la crisis energética y alimentaria, afectando significativamente las economías globales. Rusia, principal proveedor de gas natural a Europa, ha interrumpido el suministro, lo que ha elevado los precios de la energía. Asimismo, la suspensión de exportaciones de cereales y aceites vegetales desde ambas naciones ha disparado la inflación subyacente, impactando directamente en los productos básicos esenciales para millones de hogares.

2.1.1.2 ANÁLISIS INFLACIONARIO EN ESPAÑA

El análisis de la inflación general en España resalta factores clave como la disminución en los precios de alimentos esenciales y carburantes, lo que ha contribuido a moderar los costos energéticos y la inflación. Las proyecciones indican una reducción gradual de la tasa inflacionaria: 3.4% en 2023, 2.9% en 2024, 2.1% en 2025 y 1.8% en 2026, reflejando una tendencia hacia la estabilidad. Aunque las expectativas inflacionarias globales han mostrado una ligera baja, la persistencia inflacionaria en servicios, particularmente en

América Latina, podría influir en las políticas monetarias. Sin embargo, factores como la moderación en los costos energéticos son señales positivas para el control inflacionario. Además, riesgos como tensiones geopolíticas, conflictos en Ucrania y Gaza, incertidumbres económicas y posibles ajustes en mercados financieros representan desafíos para la estabilidad futura de los precios (Banco de España, 2024).




Figura 2. Inflación en el área del euro y contribución de los componentes

Fuente: (Banco de España, 2024)

En la Figura 2 se destaca la persistencia de la inflación en los servicios, la cual ha permanecido por encima de las expectativas en los últimos meses. En contraste, los precios de la energía, que son más volátiles, han experimentado una disminución reciente, mientras que las presiones inflacionarias en los alimentos y, en particular, en los bienes industriales no energéticos, han mostrado una tendencia a moderarse o se encuentran ya relativamente contenidas.




Figura 3. Evolución anual del IPC en España

Fuente: (Instituto Nacional de Estadística, 2024)

En la Figura 3 se observa que la inflación anual estimada del IPC en diciembre de 2024 es del 2,8%, según el indicador adelantado. Este dato representa un aumento de cuatro décimas respecto a noviembre, cuando la variación fue del 2,4%. El incremento se atribuye principalmente al alza en los precios de los carburantes, contrastando con la disminución registrada en diciembre de 2023. En menor medida, también influyen los precios de ocio y cultura, que muestran un incremento mayor en comparación con el mismo mes del año anterior.

2.1.1.3 ANÁLISIS INFLACIONARIO EN ESTADOS UNIDOS

En agosto de 2024, la inflación en Estados Unidos alcanzó un 2,5%, marcando su nivel más bajo desde febrero de 2021, y descendió del 2,9% registrado en julio. Esta cifra se sitúa por debajo de las expectativas del mercado y refleja una desaceleración significativa, atribuida principalmente a la disminución de los costos de la energía. Sin embargo, la tasa de inflación sigue superando el objetivo del 2,0% establecido por la Reserva Federal. Como resultado, la tendencia general de la inflación ha mostrado un ligero descenso, con una inflación media anual del 3,2% en agosto, en comparación con el 3,3% en julio (FocusEconomics [ES], 2024).



Figura 4. Tasa de inflación anual es Estados Unidos

Fuente: (Trading Economics, 2024a)

En la Figura 4 se observa que la tasa de inflación anual en EE. UU. alcanzó el 2,9% en diciembre de 2024, marcando el tercer mes consecutivo de aumento, conforme a las expectativas del mercado. Este incremento estuvo impulsado por efectos base del año anterior, particularmente en el sector energético, donde los costos disminuyeron menos de lo

previsto. Además, la inflación se aceleró en alimentos y transporte, mientras que los precios de refugios mostraron una leve desaceleración.

2.1.1.4 REDES NEURONALES EN ESPAÑA

El uso de aprendizaje automático para predecir la inflación en España y cuantificar sus impactos se implementó con modelos de regresión dinámica, Vector Autorregresivo (VAR), Vector de Corrección de Error (VECM) y redes neuronales LSTM, cada uno con distintos niveles de interpretabilidad y predictibilidad. Los modelos univariantes como VAR y VECM ofrecen interpretabilidad de las relaciones entre variables y son sensibles a factores como el precio del petróleo. En contraste, el modelo de redes neuronales LSTM, aunque menos interpretable y con menor sensibilidad a impactos en comparación con los modelos estadísticos clásicos, proporciona predicciones del IPC para 2024 cercanas al 3% y, en promedio, mantiene errores de backtesting por debajo del 1.5%, lo cual demuestra su fiabilidad en términos predictivos (Bagueiro, 2024).

El artículo "Utilización de redes neuronales en la caracterización, modelización y predicción de series temporales económicas en un entorno complejo" destaca la eficacia de las redes neuronales en la predicción de valores futuros, especialmente en sistemas complejos y de alta dimensionalidad. Los métodos comparados, como la reconstrucción del espacio de estados y el aprendizaje con redes neuronales, resultan complementarios, siendo este último más adecuado para contextos estocásticos. Además, las redes neuronales han demostrado capacidad para modelar sistemas complejos, incluso en series cortas o con ruido. Este enfoque propone un cambio de paradigma hacia modelos no lineales y aprendizaje automático, fomentando una mejor comprensión de dinámicas económicas complejas (Olmedo et al., 2004).

2.1.1.5 REDES NEURONALES EN INDONESIA

La Red Neuronal de Retropropagación (BPNN) ha demostrado ser efectiva para predecir la inflación en Indonesia, con una alta precisión reflejada en un bajo error cuadrático medio (MSE) de 0.00000424, lo que indica su capacidad para capturar relaciones no lineales en datos económicos. La flexibilidad de su arquitectura, ajustando capas y neuronas, optimiza el rendimiento para diferentes conjuntos de datos, superando métodos tradicionales como ARIMA y ANFIS. Esto posiciona al BPNN como una opción confiable para decisiones y

políticas económicas. Además, combinar BPNN con otros métodos de inteligencia artificial podría mejorar la precisión, destacando su potencial en contextos económicos complejos (Purnawansyah et al., 2019).

2.1.2 ANÁLISIS DEL MICROENTORNO

En este apartado, se examina el contexto económico de América Latina y el Caribe, enfocándose en las tendencias inflacionarias recientes y los desafíos que enfrenta la región. Se abordarán factores como la recuperación post-pandemia y las fluctuaciones de precios, así como su impacto en los hogares más vulnerables. También se presentarán estudios que utilizan redes neuronales para la predicción de la inflación, destacando su relevancia en un entorno económico cambiante y complejo.

2.1.2.1 ANÁLISIS INFLACIONARIO A NIVEL AMÉRICA LATINA Y EL CARIBE

En los últimos años, la inflación ha persistido como un desafío fundamental en América Latina y el Caribe. En 2023, Venezuela encabezó el ranking regional con una tasa de inflación cercana al 360%, mientras que la media regional fue del 13,8% (Statista, 2024a).

La inflación en América Latina y el Caribe ha aumentado significativamente, pasando de un promedio del 4% entre 2015 y 2019 al 7% a finales de 2021. Este aumento ha sido impulsado principalmente por el alza de alimentos y combustibles, que representan más del 90% de la inflación en varios países. Este fenómeno afecta especialmente a los hogares de bajos ingresos, que destinan una mayor parte de sus recursos a estos bienes esenciales, aumentando la desigualdad. Además, factores como la guerra en Ucrania y la recuperación lenta de las cadenas de suministro podrían prolongar esta tendencia, mientras que los aumentos de las tasas de interés enfriarán el crecimiento económico en el corto y mediano plazo. (Jaramillo y O'Brien, 2022)




Figura 5. Ranking de los 15 Países de América Latina y el Caribe con las Tasa de Inflación más altas en 2024

Fuente: (Statista, 2024c)

Como se muestra en la Figura 5, en 2024, Argentina lideró el ranking de países de América Latina y el Caribe con la tasa de inflación más alta, alcanzando casi el 230%. La media regional se situó en 16,75%. Se proyecta una disminución gradual de la inflación en los próximos años, con una tasa estimada del 8,49% para 2025 y una estabilización por debajo del 6% a partir de 2026.

2.1.2.2 ANÁLISIS INFLACIONARIO EN PARAGUAY

El análisis de la inflación en Paraguay, desde 1989 hasta 2021, ha identificado varios factores clave que influyen en su comportamiento. Las expectativas de inflación tienen un coeficiente de causalidad positivo de 0,52, lo que significa que un aumento del 1% en la tasa de interés de los depósitos eleva la inflación en un 0,52%. Además, se observa una correlación negativa entre la inflación y la tasa de desempleo, consistente con la curva de Phillips. Los precios internacionales de alimentos impactan la inflación, especialmente debido a la importancia de Paraguay como exportador de soja y carne. Asimismo, los precios en Argentina y Brasil afectan negativamente la inflación local, evidenciando un efecto de

contagio. Por último, el cambio climático influye negativamente en la inflación, afectando la demanda de energía y los costos de producción (Legal Cañisá, 2024).



Figura 6. Tasa de inflación en Paraguay

Fuente: (Trading Economics, 2024b)

Como se muestra en la Figura 6, la inflación anual de Paraguay aumentó al 3.8% en diciembre de 2024, frente al 3.4% en noviembre. Los mayores aumentos se dieron en alimentos y bebidas no alcohólicas, vivienda, recreación y transporte. Sin embargo, algunos sectores como restaurantes, muebles y salud vieron un incremento más lento.

2.1.2.3 ANÁLISIS INFLACIONARIO EN ARGENTINA

La inflación en Argentina entre 2004 y 2022 estuvo influenciada por varios factores clave. El tipo de cambio fue el principal determinante, contribuyendo entre un 15% y un 56% a la inflación. La tasa de interés tuvo un impacto menor, mientras que la oferta monetaria y los precios de bienes internacionales contribuyeron en un 8%. El nivel de actividad económica no resultó relevante en las simulaciones. Usando un modelo de vectores de corrección de errores (VEC), el estudio analizó las relaciones de largo y corto plazo entre las variables, bajo expectativas de inflación retrospectivas. Los resultados indican que la inflación tiene efectos recesivos a largo plazo y que la política monetaria controla la inflación de forma limitada, con inercia inflacionaria y ajustes de tarifas como factores importantes. (Banco Central de la República Argentina, 2024).




Figura 7. Evolución anual de la tasa de inflación en Argentina desde 2017 hasta 2025

Fuente: (Statista, 2024b)

Como se observa en la Figura 7, para 2024, la tasa de inflación en Argentina se estimó en 229,82%, un aumento de más de 96 puntos porcentuales en comparación con el año anterior. Este crecimiento constante desde 2017 coloca al país como el líder en inflación en América Latina, incluso por encima de Venezuela. No obstante, las proyecciones indican que en los próximos años se experimentará una disminución significativa. La persistente debilidad económica ha sido una preocupación central para la población, atribuida al estancamiento del crecimiento económico, altos niveles de deuda pública insostenible y una inflación elevada que ha afectado negativamente el poder adquisitivo.

2.1.2.4 ANÁLISIS INFLACIONARIO EN CENTROAMÉRICA

El análisis de las expectativas de inflación en Centroamérica revela varios factores determinantes en la dinámica inflacionaria regional. Las expectativas de los agentes económicos, influenciadas por decisiones de consumo e inversión, a menudo tienen sesgos no racionales. La política monetaria, mediante metas de inflación establecidas por los bancos centrales, busca estabilizar la economía y anclar esas expectativas. Factores como el crecimiento económico, la oferta y demanda agregada, el desempleo, la inversión extranjera y la estabilidad política también son cruciales. La historia inflacionaria impacta las expectativas actuales, reflejando experiencias pasadas. A pesar de los esfuerzos para anclarlas, persisten desafíos relacionados con la confianza en las instituciones y la variabilidad de la inflación (Quiñonez et al., 2024).

2.1.2.5 ANÁLISIS INFLACIONARIO EN CENTROAMÉRICA Y REPÚBLICA DOMINICANA

Al cierre de 2023, Centroamérica y República Dominicana evidenciaron avances notables en la moderación de las presiones inflacionarias. En diciembre, la inflación interanual promedio en estos países alcanzó un 2.8%, una cifra significativamente inferior al 8.0% registrado en el mismo periodo del año anterior. Nicaragua y Honduras presentaron los niveles de inflación más altos, mientras que Costa Rica experimentó una deflación interanual del 1.8%. Esta reducción se explica por la aplicación de políticas monetarias restrictivas en las economías principales, la disminución de precios en energía y alimentos, y la normalización de las cadenas de suministro y de los costos de transporte a escala global (Comisión Nacional de Bancos y seguros, 2023).




Figura 8. Tasa de inflación interanual

Fuente: (SECMCA, 2024)

La Figura 8 ilustra las tendencias de la inflación interanual en Centroamérica desde 2019 hasta 2024, distinguiendo entre las regiones CA, CARD y CAPARD. Las líneas muestran comportamientos similares, con picos inflacionarios destacados en 2022 y una disminución sostenida hacia finales de 2024. La región CARD, que incluye a Costa Rica, El Salvador, Guatemala, Honduras, Nicaragua y República Dominicana, y la región CAPARD, que agrega a Panamá, reflejan patrones inflacionarios comparables. A noviembre de 2024, los cierres inflacionarios indican una reducción significativa respecto a los niveles máximos registrados en 2022, lo que sugiere una mejora en las condiciones económicas regionales.




Figura 9. Contribución de las divisiones a la inflación interanual

Fuente: (SECMCA, 2024)

La Figura 9 compara las contribuciones porcentuales de diferentes categorías al índice de inflación en los países de Centroamérica y República Dominicana, desglosadas en alimentos, transporte, vivienda y otras (resto). Honduras y Nicaragua registran los mayores porcentajes de inflación, con una notable influencia de los alimentos. En la República Dominicana, aunque los alimentos siguen siendo un factor importante, la vivienda y el transporte también tienen un peso considerable. Guatemala muestra un menor impacto general, mientras que en Costa Rica el transporte destaca como la categoría con mayor contribución negativa. En Panamá, el impacto es mínimo, reflejando estabilidad en las categorías. Finalmente, El Salvador presenta un balance en las contribuciones, sin un componente que predomine claramente.

2.1.2.6 REDES NEURONALES A NIVEL AMÉRICA LATINA Y EL CARIBE

El uso de redes neuronales regularizadas para predecir la inflación en Colombia muestra eficacia, aunque el modelo ARIMA presenta un rendimiento ligeramente superior. La investigación evaluó 24 variables económicas, seleccionando solo 7 relevantes, lo que resalta la importancia de una adecuada selección de variables. Aunque las redes neuronales detectan patrones complejos y se adaptan a cambios en las variables inflacionarias, las limitaciones como la falta de base teórica y datos actualizados afectan la precisión de las predicciones. Estos hallazgos sugieren que, a pesar del potencial de las redes neuronales, los

modelos econométricos tradicionales como ARIMA siguen siendo relevantes en la predicción de la inflación (Loaiza Zapata, 2022).

El estudio sobre la inflación y el crecimiento económico en México muestra que las redes neuronales, especialmente el modelo LSTM, superan al modelo ARIMA en precisión de predicción. Las redes neuronales obtuvieron menores valores en el error cuadrático medio (RMSE), lo que refleja una mayor precisión. Además, capturan relaciones no lineales y patrones a largo plazo, adaptándose mejor a la complejidad de las series temporales económicas. Esta flexibilidad permite incluir más variables, ofreciendo una comprensión más completa de los factores que afectan la inflación y el crecimiento en México. A pesar de que ARIMA sigue siendo efectivo, su capacidad de adaptarse a nuevas tendencias es más limitada en comparación con las redes neuronales (Cruz Martínez et al., 2024).

2.1.3 ANÁLISIS INTERNO

En este apartado, se analiza el contexto inflacionario en Honduras, destacando las metodologías empleadas para comprender la dinámica de la inflación. Se examinarán modelos estadísticos y econométricos que permiten descomponer la inflación y evaluar su persistencia en diferentes rubros.

2.1.3.1 ANÁLISIS INFLACIONARIO EN HONDURAS

En octubre de 2024, la inflación en Honduras ha experimentado tendencias notables, destacando una inflación mensual de -0.05%, lo que evidencia una desaceleración en comparación con los meses anteriores. La inflación acumulada hasta ese mes se sitúa en 3.29%, lo que indica un comportamiento más estable de los precios en relación con el año previo. En términos interanuales, se reportó una inflación del 4.05%, lo que representa una disminución de 1.79 puntos porcentuales respecto a octubre de 2023, marcando el nivel más bajo desde abril de 2021 y sugiriendo una tendencia a la baja en la presión inflacionaria. Este descenso ha sido impulsado principalmente por la reducción en los precios de ciertos alimentos, como huevos, maíz, yuca y frijoles, así como por la disminución de los precios de los combustibles para uso vehicular y doméstico.

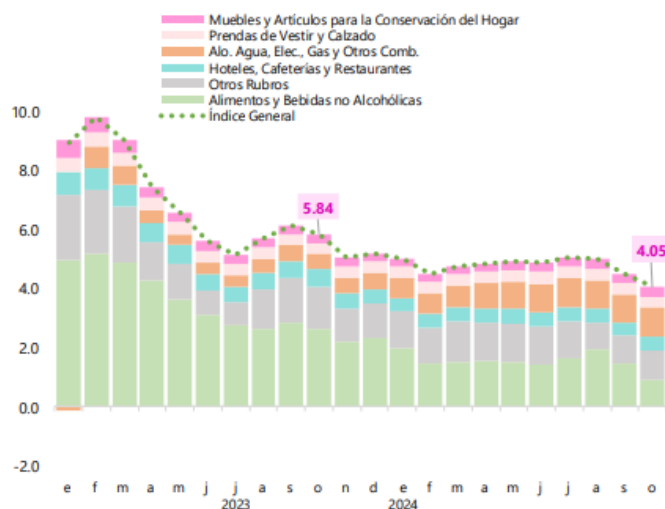


Figura 10. Aporte de la Inflación Interanual por Rubros

Fuente: (Banco Central de Honduras, 2024)

En la figura 10 se observan variaciones en los rubros que impactan la inflación interanual, destacando "Alojamiento, Agua, Electricidad, Gas y Otros Combustibles" (0.99 pp), "Alimentos y Bebidas no Alcohólicas" (0.89 pp) y "Hoteles, Cafeterías y Restaurantes" (0.46 pp), lo que sugiere que, aunque algunos sectores han registrado aumentos, otros han mostrado una disminución significativa en sus precios.

El análisis de las expectativas de inflación en Honduras revela determinantes específicos que inciden en la dinámica inflacionaria del país. Entre ellos, las expectativas de los agentes económicos juegan un papel crucial en las decisiones de consumo e inversión, aunque estos agentes no siempre logran ajustarse adecuadamente frente a choques externos. La política monetaria también es fundamental, aunque el Banco Central de Honduras aún no cuenta con un esquema formal de metas de inflación, lo que dificulta el anclaje de expectativas de manera efectiva. Además, la economía hondureña es vulnerable a choques externos, como las fluctuaciones en los precios de los commodities, es decir cambios en los precios de la materia prima y cambios en la economía global. Factores macroeconómicos, como el crecimiento económico y la estabilidad política, también influyen en el nivel de inflación. Sin embargo, persisten desafíos para fortalecer la confianza en las instituciones y mejorar la comunicación de las políticas monetarias, lo que subraya la importancia de una gestión sólida para lograr la estabilidad económica en Honduras (Quiñonez et al., 2024).

En el contexto de la inflación, la coordinación de las medidas de política monetaria, cambiaria y fiscal implementadas por el Gobierno ha sido fundamental para contener la aceleración de los niveles de precios, la cual había aumentado de manera inusitada en años anteriores, especialmente debido a la influencia de los bienes importados. Este incremento se originó a partir de las perturbaciones en la cadena de suministros provocadas por la crisis sanitaria global y se intensificó a raíz del conflicto geopolítico en Rusia. Sin embargo, durante el año 2023 se ha observado una desaceleración en la inflación, atribuida a la gradual disminución de los impactos externos relacionados con las materias primas y los combustibles en el país, lo que ha permitido que la inflación retorne a su comportamiento histórico (Banco Central de Honduras, 2023).

2.1.3.2 ENFOQUES Y TÉCNICAS DE MODELADO EN HONDURAS

En este estudio se lleva a cabo un análisis exhaustivo de la tendencia de la inflación en Honduras mediante la aplicación de un modelo multivariado que descompone los diferentes rubros que conforman el índice de precios al consumidor. Este enfoque permite identificar las diversas capas de persistencia en la inflación, revelando cómo la volatilidad de los distintos rubros puede afectar la tendencia general de la inflación a lo largo del tiempo. Para ello, se emplea la metodología del modelo de componentes no observables con volatilidad estocástica ajustada por valores atípicos, conocido como UCSVO Univariate Unobserved Components/Stochastic Volatility Outlier-Adjustment, junto con su extensión multivariada, MUCSVO Multivariate Unobserved-Components Stochastic Volatility Outlier-Adjusted. Esta metodología permite descomponer la tasa de inflación en un componente permanente y uno transitorio, teniendo en cuenta la variabilidad temporal de las varianzas de ambos componentes. Asimismo, se destaca la capacidad del modelo para detectar cambios en la persistencia de la inflación en cada rubro, lo que proporciona una estimación más precisa y detallada de la tendencia inflacionaria en Honduras (Cruz Torres, 2023).

Este caso de estudio en Honduras se centra en la identificación de umbrales de inflación que optimicen el crecimiento económico, utilizando datos anuales del período 1980-2014. La investigación emplea métodos estadísticos y econométricos para determinar

el nivel de inflación a partir del cual el crecimiento comienza a verse negativamente afectado. Los resultados estadísticos muestran que el crecimiento promedio más alto ocurre cuando la inflación se encuentra entre el 3.4% y el 6.9%, lo que sugiere la existencia de un rango óptimo. A través de un modelo de Mínimos Cuadrados Ordinarios MCO, el análisis econométrico confirma una relación no lineal entre inflación y crecimiento, indicando que cuando la inflación supera el umbral de entre el 7.0% y el 8.0%, se observan efectos adversos significativos sobre el crecimiento económico. Los hallazgos subrayan la importancia de mantener la inflación dentro de este rango óptimo para promover un desarrollo económico sostenido en el país, señalando la necesidad de políticas monetarias que garanticen una inflación baja y estable (Álvarez, 2016).

2.2 CONCEPTUALIZACIÓN

2.2.1 VARIABLE DEPENDIENTE

2.2.1.1 INFLACIÓN

El término inflación proviene del latín *inflatio*, que significa "hinchar" o "expandir", y comenzó a utilizarse en el siglo XIX para describir el aumento de la cantidad de dinero en circulación, lo que provocaba un incremento en los precios de los bienes y servicios. Con el tiempo, este concepto se amplió para incluir los efectos sobre el poder adquisitivo de la moneda. Aunque se considera un fenómeno monetario a largo plazo, su estudio es fundamental para los bancos centrales. El índice de precios al consumidor (IPC) se emplea comúnmente para medirla, pero no siempre refleja de manera completa el fenómeno, ya que puede verse influenciado por factores externos como fluctuaciones estacionales y ajustes fiscales (Mateos y Gaytán, 1998).

La inflación se define como un incremento sostenido y generalizado en los precios de productos y servicios dentro de una economía. Este fenómeno se suele evaluar mediante la variación porcentual del Índice de Precios al Consumidor (IPC), el cual refleja el cambio en los precios promedio de una canasta representativa de bienes de consumo. Esta métrica es fundamental para analizar la evolución del costo de vida y su impacto sobre el poder adquisitivo de las familias (Gutiérrez Andrade y Zurita Moreno, 2006).

2.2.2 VARIABLES INDEPENDIENTES

2.2.2.1 SECTOR MONETARIO/FINANCIERO

El origen del sector monetario y financiero se remonta a la necesidad de regular y gestionar el flujo de dinero dentro de una economía. Desde los primeros intercambios comerciales, las sociedades comenzaron a reconocer la importancia de contar con sistemas que permitieran el intercambio de bienes y servicios de manera eficiente. A medida que las economías crecían y se complejizaban, surgieron instituciones como bancos centrales y entidades financieras que asumieron el rol de regular la cantidad de dinero en circulación, establecer tasas de interés y garantizar la estabilidad del sistema financiero. Estos mecanismos se consolidaron con el tiempo para asegurar el funcionamiento adecuado de los mercados y la estabilidad macroeconómica, siendo fundamentales para el desarrollo de las políticas monetarias modernas (Argandoña, 1990).

Según el Banco Central del Ecuador (2015), el sector monetario y financiero abarca todas las transacciones relacionadas con la administración del dinero, los servicios bancarios, y las políticas monetarias establecidas por las instituciones financieras de una nación. Este sector permite la fluidez del capital entre ahorradores e inversionistas, lo que contribuye a la estabilidad económica y al control de factores como la inflación y las tasas de interés.

2.2.2.2 SECTOR EXTERNO/COMERCIAL

El origen del sector externo comercial se encuentra en el desarrollo de los intercambios comerciales entre diferentes regiones y países. Desde la antigüedad, las civilizaciones han recurrido al comercio con otras naciones para obtener recursos que no se encontraban en su territorio, lo que llevó al establecimiento de rutas comerciales internacionales. A medida que las economías se globalizaban, surgió la necesidad de regular estos intercambios, lo que dio lugar a la creación de políticas comerciales y acuerdos entre naciones. Este sector abarca el comercio de bienes y servicios, las inversiones extranjeras, y las relaciones económicas internacionales, desempeñando un papel crucial en el crecimiento y la integración de los mercados globales (Heath, 2012).

La viabilidad comercial de una economía se manifiesta en la capacidad de interactuar efectivamente con mercados internacionales, facilitando así el intercambio de bienes, servicios, e inversiones. Según el Banco Central del Ecuador (2012), el sector externo

representa las transacciones económicas con otros países, englobando importaciones, exportaciones y la gestión de transferencias y remesas, lo cual impacta de manera significativa en la balanza de pagos y la posición comercial de una nación.

2.2.2.3 ACTIVIDAD ECONÓMICA

El origen de la actividad económica se remonta a los primeros sistemas de intercambio entre seres humanos, cuando las sociedades primitivas comenzaron a satisfacer sus necesidades a través de la caza, la agricultura y la recolección. Con el tiempo, estas actividades evolucionaron a medida que las comunidades se establecían y organizaban. El surgimiento de la agricultura, en particular, permitió la acumulación de excedentes y el desarrollo de la especialización del trabajo, lo que facilitó el intercambio de bienes y servicios (Argandoña, 1990).

La actividad económica, según el Instituto Nacional de Estadística e Informática (2018), se refiere a la generación de valor a través de la producción de bienes y servicios que responden a las necesidades de la sociedad. Este proceso incluye la extracción, transformación y comercialización de recursos para fomentar el crecimiento económico y la generación de riqueza.

2.2.3 VARIABLES MACROECONÓMICAS

El origen de las variables macroeconómicas se remonta a los primeros estudios sobre el comportamiento global de las economías, especialmente durante el desarrollo del pensamiento económico en los siglos XVIII y XIX. Las variables macroeconómicas son indicadores que reflejan el estado y comportamiento de la economía en su conjunto. Estos indicadores permiten medir y evaluar aspectos clave como el crecimiento económico, la inflación, el desempleo y la estabilidad financiera de un país. Estas variables son esenciales para entender la dinámica económica a gran escala, ya que proporcionan información crítica sobre la salud y el desempeño de la economía, así como sobre las políticas públicas que impactan el bienestar social y económico de la población (Cardona Echeverri et al., 2016).

2.2.4 VARIABLES MICROECONÓMICAS

Las variables microeconómicas son factores que influyen en las decisiones y comportamientos de individuos, empresas y otros agentes económicos en mercados específicos. Se enfocan en el análisis de aspectos como el precio, la demanda, la oferta y los costos de producción, que afectan directamente el consumo, la producción y el intercambio. Su estudio permite comprender cómo se asignan los recursos y cómo interactúan los agentes económicos en mercados particulares. Desarrollada en el siglo XIX por economistas como Alfred Marshall, la microeconomía utiliza estas variables para explicar el comportamiento económico a nivel individual (Uquillas y González, 2017).

2.2.5 OTRAS CONCEPTUALIZACIONES

2.2.5.1 MACHINE LEARNING

El origen del machine learning (aprendizaje automático) se remonta a mediados del siglo XX, con el desarrollo de la inteligencia artificial (IA) y el estudio de algoritmos que permiten a las máquinas aprender a partir de datos y mejorar su rendimiento sin ser explícitamente programadas para ello. El concepto de aprendizaje automático tiene sus raíces en la teoría de la estadística y la inteligencia artificial, donde se planteaba la idea de que las máquinas podrían aprender a reconocer patrones y hacer predicciones basadas en experiencias pasadas, similar a cómo lo hacen los humanos (Saladrigas, 2022).

El Machine Learning (aprendizaje automático o ML, por sus siglas en inglés) es una rama de la ciencia computacional que permite a los ordenadores “aprender” a partir de datos. En lugar de programar soluciones específicas para cada tarea, como en la programación convencional, el aprendizaje automático se centra en desarrollar algoritmos genéricos capaces de identificar patrones en distintos tipos de datos. Estos algoritmos, una vez entrenados, pueden adaptarse a nuevas situaciones, ofreciendo soluciones automatizadas y optimizadas para diversas aplicaciones (Bobadilla, 2020, p. 13).

2.2.5.2 APRENDIZAJE SUPERVISADO

El origen del aprendizaje supervisado se encuentra en los primeros trabajos en inteligencia artificial (IA) y aprendizaje automático en la década de 1950. El concepto de este tipo de aprendizaje surgió con la idea de que las máquinas pueden aprender a partir de

ejemplos etiquetados, es decir, a partir de un conjunto de datos en el que cada entrada está asociada con una salida correcta previamente conocida. Esta idea se inspiró en la manera en que los seres humanos aprenden, mediante ejemplos que les enseñan las respuestas correctas (Saladrigas, 2022).

El aprendizaje supervisado en machine learning se utiliza cuando cada dato o conjunto de datos de entrada (muestra) está asociado a una etiqueta que indica el resultado deseado (Bobadilla, 2020, p. 14).

2.2.5.3 APRENDIZAJE PROFUNDO

El Aprendizaje Profundo, o *Deep Learning*, tiene sus raíces en la década de 1940, con el desarrollo de las primeras redes neuronales, como el perceptrón de Frank Rosenblatt en 1958. Sin embargo, su verdadero impulso ocurrió a finales del siglo XX y principios del XXI, gracias a avances en computación, grandes volúmenes de datos y mejoras en algoritmos. Este subcampo de *machine learning* utiliza redes neuronales jerárquicas que imitan la estructura del cerebro humano. Las redes, compuestas por capas de nodos interconectados, procesan y analizan datos de manera no lineal, permitiendo interpretar patrones complejos. Hoy, el aprendizaje profundo es clave en áreas como visión por computadora, procesamiento de lenguaje natural y reconocimiento de voz (Centeno Franco, 2019, p. 3).

2.2.5.4 RED NEURONAL ARTIFICIAL

Las redes neuronales artificiales se remontan a la década de 1940, cuando los primeros investigadores comenzaron a explorar la idea de imitar el funcionamiento del cerebro humano para resolver problemas computacionales. En 1943, Warren McCulloch y Walter Pitts desarrollaron el primer modelo matemático de una neurona artificial, basado en el comportamiento de las neuronas biológicas, lo que marcó el inicio de la teoría de las redes neuronales. Este modelo simplificado de una neurona se utilizó para representar funciones lógicas y fue un paso crucial en el desarrollo de las redes neuronales (Tablada y Torres, 2009).

Una Red Neuronal Artificial (RNA) es un modelo matemático inspirado en el funcionamiento biológico de las neuronas y la estructura del cerebro humano. Esta estructura permite procesar información de manera similar al cerebro, conectando múltiples nodos (o "neuronas") que colaboran para identificar patrones y realizar tareas de clasificación y

predicción en los datos (Tablada y Torres, 2009, p. 1).

2.2.5.5 SERIES DE TIEMPO

Las raíces del análisis de series de tiempo se encuentran en los estudios estadísticos y económicos del siglo XIX, cuando se empezó a observar la importancia de los datos secuenciales, como los precios y las tasas de crecimiento. Una serie temporal es una secuencia de observaciones registradas en momentos específicos, organizadas de manera cronológica y con intervalos uniformes entre cada medición. Este orden cronológico hace que los datos tiendan a ser interdependientes, permitiendo analizar tendencias, patrones y cambios a lo largo del tiempo (Villavicencio, 2010, p. 1).

2.2.5.6 MINERÍA DE DATOS

La minería de datos (MD) es un intento de buscarle sentido a la explosión de información que actualmente puede ser almacenada y procesada mediante tecnologías avanzadas. Esta disciplina utiliza algoritmos, técnicas estadísticas y modelos matemáticos para explorar grandes volúmenes de datos con el fin de descubrir patrones ocultos, tendencias, correlaciones y asociaciones que son útiles para la toma de decisiones, la predicción o la optimización de procesos (Riquelme et al., 2006).

La minería de datos es el proceso de extraer información relevante y valiosa de grandes bases de datos, identificando patrones, tendencias y correlaciones ocultas que proporcionan inteligencia del negocio. Esta técnica permite a los usuarios realizar predicciones que resuelven problemas específicos, otorgando así una ventaja competitiva. Las herramientas de minería de datos ayudan a prever nuevas perspectivas y a anticipar la situación futura de la empresa, lo que facilita la toma de decisiones proactivas y estratégicas en el ámbito empresarial.

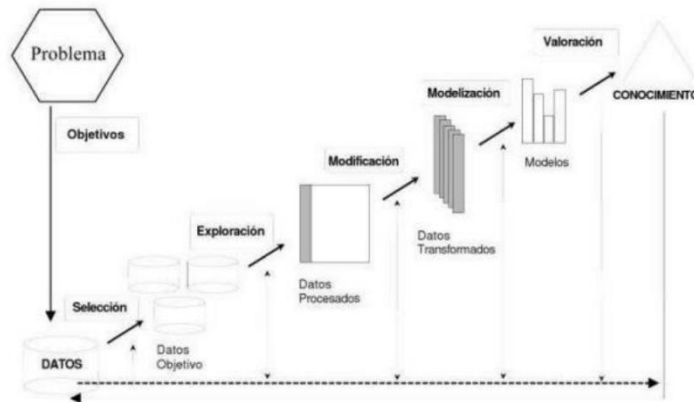


Figura 11. Minería de datos

Fuente: (Lugo Cabrera y López Herrera, 2018)

En la Figura 11, se define el concepto de minería de datos como el proceso que involucra cinco etapas clave: Seleccionar, Explorar, Modificar, Modelizar y Valorar grandes volúmenes de datos. El objetivo principal de este proceso es descubrir patrones desconocidos que puedan ofrecer una ventaja comparativa. A través de estas etapas, se busca transformar los datos en información útil que permita tomar decisiones más informadas y estratégicas para mejorar el rendimiento y la competitividad de la organización.

2.3 TEORÍAS DE SUSTENTO

En este apartado se exponen las teorías fundamentales que sustentan esta investigación. Dichas teorías no solo proporcionan un marco conceptual robusto, sino que también articulan los argumentos y fundamentos esenciales que resaltan la relevancia del desafío abordado.

2.3.1 BASES TEÓRICAS

2.3.1.1 TEORÍA ECONÓMICA

La teoría económica es clave para analizar y comprender los problemas económicos de la sociedad. A lo largo del tiempo, ha evolucionado para adaptarse a los cambios, incorporando principios como la ventaja comparativa, que muestra cómo los países se benefician del comercio. También reconoce la inestabilidad inherente de la economía

capitalista, destacando la necesidad de herramientas para abordar estas fluctuaciones. La división entre macroeconomía y microeconomía ha sido fundamental para entender las dinámicas económicas a distintos niveles. Este enfoque dual permite analizar desde la renta nacional y los agregados económicos hasta las decisiones individuales y la asignación de recursos, ofreciendo una visión más profunda de los fenómenos económicos y su impacto social (Mancera y Agustín, 2003).

La teoría económica resalta la existencia de una relación negativa entre la inflación y el crecimiento económico, la cual puede manifestarse de múltiples maneras, Fischer destaca el papel crucial que desempeña la inflación en la estabilidad macroeconómica de un país (Álvarez, 2016).

La teoría económica es una disciplina que estudia cómo se organizan y distribuyen los recursos escasos para satisfacer las necesidades humanas. Se divide en microeconomía, que analiza las decisiones individuales de consumidores y empresas, y macroeconomía, que se enfoca en el comportamiento global de la economía, abarcando variables como el PIB, la inflación y el desempleo. Existen diversas corrientes de pensamiento dentro de la teoría económica, como el enfoque clásico, el keynesianismo y el monetarismo, cada uno con sus propias interpretaciones y propuestas sobre el funcionamiento de la economía y las políticas económicas más adecuadas (Enciclopedia Financiera, 2023).

La Teoría Económica busca explicar el funcionamiento de las economías y la interacción de los agentes económicos en diversas áreas de la vida social. Su aplicación abarca no solo la sociedad, sino también campos como los negocios, la política, la educación, la salud y más, extendiendo su influencia a aspectos como la delincuencia, la familia y la guerra. Se distingue entre economía positiva, que describe la realidad económica tal como es, y economía normativa, que defiende lo que debería ser. Además, se diferencian la economía convencional, centrada en el individualismo y el equilibrio, y la economía heterodoxa, que aborda temas más radicales como las instituciones y la estructura social, lo que refleja el crecimiento del imperialismo económico en las ciencias sociales (Enciclopedia Financiera, 2023).

Según Herbrich et al. (1999), existe un consenso generalizado entre la mayoría de los economistas en cuanto a que la inflación es principalmente un fenómeno monetario a

largo plazo. Este entendimiento se basa en la relación fundamental entre la cantidad de dinero en circulación y los niveles de precios en una economía, además, se reconoce ampliamente que los bancos centrales desempeñan un papel central y monopolístico en la formulación y ejecución de la política monetaria, lo que les confiere una influencia significativa en la gestión de la inflación y la estabilidad económica.

En la teoría económica, una de las relaciones clave es la que vincula la tasa de inflación con la tasa de crecimiento económico y la expansión de la oferta monetaria a mediano y largo plazo. Esta relación sostiene que el crecimiento de la oferta monetaria debe estar equilibrado con el crecimiento potencial de la economía. Si la expansión monetaria excede las necesidades del crecimiento económico, se generarán presiones inflacionarias. De esta manera, el aumento de los precios está directamente relacionado con el ritmo de expansión de la oferta de dinero en circulación. Esta interacción se aplica a cualquier economía, sin importar su estructura, apertura comercial o régimen cambiario. Es un principio fundamental en la teoría económica que resalta la importancia del equilibrio entre oferta monetaria, crecimiento económico e inflación (Schwartz y Sybel, 1999).

La teoría económica contemporánea integra diversas corrientes y conceptos desarrollados desde el siglo XX, destacando la relevancia de las expectativas y la racionalidad en la toma de decisiones. La Nueva Economía Clásica resalta la ineficacia de políticas monetarias predecibles en el largo plazo, mientras que la Nueva Economía Keynesiana subraya el impacto de las rigideces de precios y salarios. La neutralidad del dinero establece que los cambios en la oferta monetaria solo afectan los precios a largo plazo, y la curva de Phillips revisada muestra que no existe un trade-off sostenido entre inflación y desempleo. Además, la transparencia y credibilidad de los bancos centrales son esenciales para anclar expectativas y fomentar estabilidad económica (León León y de la Rosa Mendoza, 2005).

2.3.1.2 TEORÍA DE POLÍTICA MONETARIA

La teoría de la política monetaria se enfoca en la interacción entre los bancos centrales y el público, buscando controlar la inflación y promover la estabilidad económica a través de una comunicación estratégica. La independencia del banco central es crucial, ya que minimiza los sesgos inflacionarios y refuerza la credibilidad de las políticas. Esta credibilidad

se logra mediante políticas consistentes y transparentes que reducen la inflación, fundamentales para el bienestar social. Además, la inflación genera ineficiencias y afecta la distribución del ingreso. Las políticas deben equilibrar rigor y flexibilidad, aprovechando la independencia del banco central. También se reconoce que los efectos de la política monetaria son rezagados, por lo que las decisiones deben ser oportunas y bien comunicadas para gestionar las expectativas inflacionarias (Schwartz y Galván, 1999).

Según Friedman (1984), la política monetaria puede ofrecer señales significativas sobre las futuras tendencias inflacionarias, aunque no sea una causa directa de la inflación. Argumenta que los cambios en la oferta de dinero y las medidas de los bancos centrales pueden ser indicadores fiables de las presiones inflacionarias. Aunque las políticas monetarias expansivas no causan necesariamente inflación, su impacto en la cantidad de dinero en circulación puede influir en los precios a largo plazo. Además, advierte sobre los efectos rezagados de la política monetaria, destacando que los cambios en la oferta de dinero pueden tardar en reflejarse en los precios, lo que subraya la importancia de una gestión cuidadosa para evitar presiones inflacionarias.

La política monetaria tiene el potencial de reducir la inflación a largo plazo, pero la transición hacia la estabilidad de precios puede generar costos en términos de producto, ya que los agentes económicos suelen tardar en adaptarse a las nuevas condiciones. Por ello, es fundamental que las autoridades monetarias eviten utilizar las políticas monetarias para sorprender o engañar a los agentes privados. La política monetaria se basa en establecer una meta de inflación de manera anticipada y en responder de manera discrecional ante choques que afecten el producto. Sin embargo, algunos de estos choques, como componentes aleatorios de la inflación, pueden surgir después de que se adopten las políticas. A pesar de su mandato de estabilidad de precios, el banco central puede tomar medidas contra cíclicas, siempre que se asegure de que estas no generen presiones inflacionarias adicionales (Reyes y Gómez, 2000)

La política monetaria es la acción del banco central para influir en las condiciones monetarias y financieras con el objetivo de promover el crecimiento económico, aumentar el empleo y mantener la estabilidad de precios. Desde otra perspectiva, implica decisiones conscientes, o incluso inacciones deliberadas, por parte de las autoridades monetarias para

modificar la cantidad, disponibilidad o coste del dinero. Estos cambios buscan contribuir al cumplimiento de objetivos clave de la política económica, siendo la estabilidad de precios el más relevante. Además, la política monetaria puede apoyar un crecimiento económico sostenido y favorecer el equilibrio externo, integrándose como una herramienta esencial en la gestión económica (León León y de la Rosa Mendoza, 2005).

La política monetaria influye en variables clave del sistema económico, como la producción, el empleo, los precios y la balanza de pagos. No obstante, la búsqueda de crecimiento económico y generación de empleo conlleva costos asociados a presiones inflacionarias. Tras la Segunda Guerra Mundial y hasta los años setenta, los bancos centrales priorizaban estas relaciones, considerando la inflación como un costo aceptable para fomentar el empleo y el crecimiento, reflejando un enfoque de equilibrio económico que aún suscita debate en la política macroeconómica actual (León León y de la Rosa Mendoza, 2005).

Los instrumentos de la política monetaria permiten a los bancos centrales influir en las condiciones financieras para garantizar la estabilidad de precios. Aunque no controlan directamente la inflación, actúan sobre las tasas de interés o el dinero y crédito en la economía. En las últimas décadas, se han abandonado los instrumentos directos, como el control de tasas o créditos, por distorsionar mercados y fomentar la desintermediación. En su lugar, predominan instrumentos indirectos como las operaciones de mercado abierto, que ajustan la base monetaria; el encaje legal, que afecta el multiplicador monetario; y los servicios permanentes, como créditos de liquidez colateralizados, asegurando el funcionamiento del sistema de pagos. Estos mecanismos reflejan una gestión financiera más moderna y eficiente (Orellana R et al., 2000).

2.3.1.3 TEORÍA DE ANALÍTICA PREDICTIVA

La teoría de la analítica predictiva es clave en la analítica de negocios, ya que utiliza datos y modelos estadísticos para anticipar resultados futuros basados en patrones históricos. Este enfoque permite a las organizaciones prever tendencias y comportamientos, proporcionando un marco para tomar decisiones estratégicas informadas. Integra técnicas avanzadas como machine learning y data mining, que descubren patrones ocultos en grandes volúmenes de datos. Así, las empresas pueden identificar oportunidades, optimizar procesos

y obtener ventajas competitivas. Sin embargo, su implementación enfrenta desafíos, como garantizar la calidad de los datos y la correcta interpretación de los resultados. La analítica predictiva transforma la toma de decisiones en un entorno empresarial dinámico (Mora, 2018).

La analítica predictiva se ha convertido en una herramienta crucial para empresas y organizaciones, permitiéndoles no solo comprender su estado actual, sino también predecir su evolución futura y tomar decisiones más informadas. Aunque el análisis de datos no es algo nuevo, la integración de tecnologías avanzadas como el big data y la minería de datos ha transformado este proceso, facilitando el manejo de grandes volúmenes de información. Gracias a estas tecnologías, hoy en día es posible analizar datos no estructurados y realizar predicciones en tiempo real, lo que otorga a las empresas una ventaja significativa para alcanzar sus objetivos estratégicos (Lugo Cabrera y López Herrera, 2018).

El Análisis Predictivo o Analítica Predictiva permite a las empresas prever resultados futuros y actuar en consecuencia, ya sea favoreciendo un evento positivo o evitando uno negativo. Este proceso se organiza en tres niveles: descriptivo, diagnóstico y predictivo, con el fin de analizar los datos y establecer predicciones. Además, incluye un nivel prescriptivo, que define las acciones a tomar para influir en los resultados. Para implementar una estrategia de analítica predictiva, es esencial conocer bien el negocio y los datos disponibles, crear un modelo adecuado y poner en práctica una estrategia que permita alcanzar los objetivos definidos de manera efectiva (BlackBeast, 2024).

La analítica predictiva se basa en métodos matemáticos avanzados, que incluyen análisis estadísticos, minería de datos, modelos predictivos y aprendizaje automático, entre otros. Su principal función es pronosticar eventos futuros mediante el desarrollo de modelos de predicción. Al aplicar estos métodos, las empresas pueden anticipar resultados y tomar decisiones informadas para influir en el futuro, mejorando su capacidad para gestionar riesgos y aprovechar oportunidades (Luna Pérez y Vázquez Álvarez, 2019).

La complejidad en la recopilación, limpieza y análisis de datos representa un desafío significativo en la implementación de la analítica predictiva. Las empresas deben gestionar grandes volúmenes de datos dispersos y heterogéneos, lo que dificulta el análisis y puede afectar la calidad de los resultados predictivos. Para superar este obstáculo, se requieren

soluciones que faciliten la gestión y preparación de los datos, como herramientas de integración y plataformas de analítica unificada. Además, la calidad de los datos es crucial para garantizar la precisión y confiabilidad de los modelos predictivos, ya que los datos pueden variar considerablemente en términos de exactitud, integridad y consistencia (Calle García et al., 2024).

En un entorno donde los datos crecen de manera constante, lo que hace que la analítica sea esencial para comprenderlos. Sin ella, sería difícil obtener claridad sobre los eventos pasados y futuros. En este contexto, existen diferentes tipos de análisis: uno de ellos es la analítica descriptiva, que se ocupa de entender lo que ha sucedido, y otro es la analítica predictiva, que busca prever lo que ocurrirá. La necesidad de analizar datos históricos ha impulsado el desarrollo de la inteligencia empresarial, una disciplina que facilita la toma de decisiones basada en el análisis de datos pasados y actuales (Guazzelli, 2012).

La analítica predictiva es una herramienta clave para evitar la repetición de errores previos, ya que permite identificar patrones y tendencias en los datos históricos. Al analizar información pasada, esta técnica ayuda a prever posibles situaciones futuras y tomar decisiones informadas que prevengan la ocurrencia de errores ya conocidos. De este modo, las organizaciones pueden optimizar sus procesos, mejorar su eficiencia y reducir riesgos al anticipar y corregir problemas antes de que se materialicen (Barrera Bolivar, 2020).

La analítica predictiva se caracteriza por varios atributos clave. En primer lugar, se enfoca en la predicción, a diferencia de la analítica descriptiva que busca explorar los datos desde diversas perspectivas. El objetivo principal de la analítica predictiva es construir modelos que anticipen valores futuros de variables relevantes. Además, se destaca por su orientación a obtener resultados específicos y relevantes para el negocio, buscando generar modelos precisos que ofrezcan predicciones confiables. A medida que avanza, la analítica predictiva se está democratizando, permitiendo que usuarios de negocio, no solo expertos en datos, puedan aplicar modelos predictivos gracias a interfaces y herramientas de fácil uso, lo que facilita su integración en la toma de decisiones empresariales (Alija, 2020).

2.3.2 METODOLOGÍAS DESARROLLADAS POR OTROS INVESTIGADORES

En este trabajo de investigación, se emplean enfoques metodológicos orientados a la implementación de modelos predictivos, con el fin de lograr resultados más precisos y bien fundamentados.

2.3.2.1 REGRESIÓN LINEAL

La regresión lineal es una técnica estadística que se utiliza para analizar la relación entre una variable dependiente y una o más variables independientes, expresando esta relación mediante una función matemática. Dentro de esta técnica, se distinguen dos tipos principales: la regresión lineal simple y la regresión lineal múltiple. La regresión lineal simple establece una relación lineal entre dos variables, permitiendo el análisis de fenómenos donde una única variable independiente influye sobre la variable dependiente. Sin embargo, en contextos más complejos, donde intervienen múltiples factores, la regresión lineal múltiple se convierte en una herramienta más adecuada.

Este enfoque permite modelar la influencia de varias variables independientes sobre una sola variable dependiente, lo que resulta fundamental para la comprensión de fenómenos donde la interacción de múltiples factores es relevante. En el modelo de regresión lineal múltiple, es esencial realizar pruebas de heterocedasticidad, multicolinealidad y especificación para asegurar la validez de los resultados. Asimismo, para obtener estimaciones confiables, es necesario que la relación entre las variables sea lineal (linealizable) y que las perturbaciones cumplan con ciertas condiciones, como tener media cero y ser homocedásticas y no autocorrelacionadas (Montero Granados, 2016).

2.3.2.2 MODELOS ARIMA

Los modelos ARIMA (Autorregresivo Integrado de Media Móvil) son herramientas estadísticas esenciales para el análisis y pronóstico de series temporales. Este enfoque combina tres componentes fundamentales: autorregresivo (AR), integrado (I) y de media móvil (MA), con el objetivo de transformar una serie temporal en una que sea estacionaria, lo que es crucial para la validez de muchos métodos de pronóstico.

El componente autorregresivo establece relaciones entre el valor actual de la serie y sus valores pasados, mientras que el componente integrado se ocupa de la diferenciación

necesaria para eliminar tendencias y estacionalidades, garantizando así la estacionariedad de la serie. Por su parte, el componente de media móvil modela el error de predicción mediante una combinación lineal de errores pasados, lo que permite capturar la influencia de estos en las futuras predicciones. En conjunto, los modelos ARIMA se utilizan ampliamente para prever el comportamiento de series temporales que presentan patrones estacionales o tendencias a lo largo del tiempo (Mora, 2018).

2.3.2.3 MODELOS DE VECTORES AUTORREGRESIVOS

Los Modelos Vectoriales Autorregresivos (VAR) constituyen herramientas econométricas fundamentales para el análisis de las interacciones dinámicas entre múltiples variables a lo largo del tiempo. Estos modelos se estructuran como un sistema de ecuaciones simultáneas en el que cada variable es explicada tanto por sus propios retardos como por los de las demás variables involucradas, lo que facilita el modelado de relaciones de dependencia sin imponer restricciones sobre la estructura del modelo. La estimación de un modelo VAR requiere la selección adecuada del número de retardos, evitando así la sobre parametrización y empleando contrastes de especificación para garantizar que la autocorrelación en los términos de error sea eliminada.

La identificación de un modelo VAR es crucial, ya que permite distinguir las relaciones causales entre las variables, utilizando técnicas como la identificación ortogonal mediante la descomposición de Cholesky. Además, las funciones de respuesta al impulso son una herramienta valiosa para evaluar el impacto de perturbaciones en una variable sobre las demás a lo largo del tiempo. Los modelos VAR son particularmente ventajosos en contextos donde se evidencia simultaneidad entre variables, dado que no requieren la identificación de variables exógenas. Asimismo, los Modelos VAR Estructurales introducen estrategias de identificación basadas en teorías económicas, lo que facilita una interpretación más clara de las relaciones entre las variables (Novales, 2017).

2.3.2.4 REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales (RNA) son modelos computacionales que se inspiran en el funcionamiento del cerebro humano, diseñados para procesar información de manera análoga a las neuronas biológicas. Compuestas por nodos interconectados, estas redes trabajan en conjunto para resolver problemas complejos, especialmente aquellos que

implican patrones no lineales y datos difíciles de modelar mediante métodos matemáticos convencionales. Una de las características distintivas de las RNA es su estructura jerárquica, organizada en capas donde cada una cuenta con múltiples neuronas que realizan cálculos y transformaciones sobre los datos de entrada. Estas redes poseen la capacidad de aprender a partir de los datos a través de procesos de entrenamiento, ajustando los pesos de las conexiones entre las neuronas para mejorar la precisión de sus predicciones.

Su versatilidad les permite ser aplicadas en diversos campos, tales como el reconocimiento de patrones, el análisis de series temporales, el procesamiento de señales y el modelado de sistemas complejos. Desde sus inicios en la década de 1940, el interés por las RNA ha crecido considerablemente, especialmente a partir de 1986, cuando avances en algoritmos de aprendizaje y en capacidad computacional propiciaron un resurgimiento en su investigación y desarrollo. A pesar de sus numerosas ventajas, como la capacidad para modelar relaciones complejas y su adaptabilidad a diferentes tipos de datos, las RNA también presentan desventajas, incluyendo la necesidad de grandes volúmenes de datos para un entrenamiento efectivo, la propensión al sobreajuste y la dificultad de interpretación de su funcionamiento interno, a menudo descrito como una "caja negra". (Rivas Asanza y Mazón Olivo, 2018)

2.3.3 INSTRUMENTOS UTILIZADOS

En el desarrollo de redes neuronales artificiales (RNA), se emplean diversos instrumentos y herramientas que facilitan su diseño, entrenamiento y evaluación. Entre los más relevantes se encuentran frameworks y bibliotecas de programación como TensorFlow y Keras, que permiten construir y entrenar modelos de aprendizaje automático de manera eficiente. Además, herramientas de visualización como TensorBoard, junto con bibliotecas como Matplotlib y Seaborn, son esenciales para monitorear el desempeño de los modelos y analizar los resultados obtenidos. Los entornos de desarrollo, como Jupyter Notebook y Google Colab, proporcionan plataformas interactivas que facilitan la experimentación y ejecución del código en Python, optimizando el proceso de desarrollo.

Para el preprocesamiento de datos, se utilizan bibliotecas como Pandas y NumPy, que permiten manipular y analizar conjuntos de datos de manera eficaz. Asimismo, software como MATLAB y Weka contribuyen a la simulación y modelado de RNA. Finalmente,

plataformas de aprendizaje automático como Microsoft Azure Machine Learning y Amazon SageMaker permiten a los desarrolladores construir y desplegar modelos a gran escala. Estos instrumentos son cruciales para la implementación exitosa de las RNA en aplicaciones diversas, desde el reconocimiento de patrones hasta el análisis de datos complejos (Rivas Asanza y Mazón Olivo, 2018).

Para el análisis y pronóstico de series de tiempo, se emplean diversas herramientas y software que facilitan la implementación de modelos como ARIMA, VAR y redes neuronales artificiales. Entre ellos, R se destaca como un lenguaje de programación robusto que ofrece paquetes especializados, como `forecast` para modelos ARIMA y `vars` para modelos VAR, siendo ideal para un análisis estadístico avanzado. Python, por su parte, es altamente versátil, contando con bibliotecas como `pandas`, `statsmodels` y `scikit-learn`, así como TensorFlow y Keras para el desarrollo de redes neuronales. EViews es un software especializado en econometría que permite la estimación de modelos econométricos y es comúnmente utilizado en análisis económicos y financieros.

MATLAB proporciona herramientas para el análisis numérico y visualización de datos, siendo ampliamente utilizado en ingeniería y ciencias aplicadas. Además, SAS y SPSS son software de análisis estadístico que incluyen procedimientos para modelado de series de tiempo, siendo particularmente útiles en la industria y la investigación social, respectivamente. Stata también ofrece capacidades para el modelado econométrico. Aunque Excel es una herramienta más básica, permite realizar análisis de series de tiempo de manera sencilla. Herramientas de minería de datos como RapidMiner y KNIME permiten construir y entrenar modelos de redes neuronales sin necesidad de programación. Estas herramientas son esenciales para proporcionar a analistas y economistas la flexibilidad y precisión necesarias en sus estudios de series de tiempo (Mora, 2018).

2.4 . MARCO LEGAL

En esta sección se abordarán las leyes y normativas más importantes que enmarcan el análisis y control de la inflación en Honduras. Se incluirán disposiciones de la Constitución de la República, la Ley del Banco Central de Honduras y otras normativas clave, que establecen los lineamientos para la estabilidad económica y financiera del país. Estas leyes son fundamentales para comprender las políticas monetarias, cambiarias y fiscales que

influyen en la variación de los precios y, por ende, en el fenómeno inflacionario.

El artículo 329 de la constitución de la república de Honduras indica que el Estado es responsable de promover el desarrollo económico y social del país mediante una planificación estratégica a mediano y largo plazo. Los planes de desarrollo formulados en este contexto serán de cumplimiento obligatorio para los gobiernos futuros, garantizando la continuidad de las políticas de crecimiento y progreso social (La Editora, 2013, p. 79).

El artículo 342 de la constitución de la república de Honduras otorga al Banco Central de Honduras la responsabilidad exclusiva de la emisión monetaria y la formulación de la política monetaria, crediticia y cambiaria del país. A través de esta regulación, el Estado busca mantener la estabilidad financiera y económica, coordinando estas políticas con los objetivos económicos nacionales (La Editora, 2013, p. 81).

La Ley del Banco Central de Honduras establece al Banco Central de Honduras (BCH) como la entidad principal responsable de regular la oferta monetaria y controlar la inflación. La ley le otorga al BCH la tarea de formular y ejecutar políticas monetarias, crediticias y cambiarias, lo que implica el ajuste de la tasa de interés de referencia y la regulación de la cantidad de dinero en circulación, con el objetivo de mantener la estabilidad de precios. Además, la ley faculta al BCH para intervenir en el mercado de divisas y estabilizar el valor del lempira, lo cual es crucial para mitigar los efectos de la inflación y asegurar la estabilidad económica del país (Banco Central de Honduras, 2004).

El Código Tributario de Honduras establece las bases legales para la recaudación de impuestos y la estructura impositiva, regulando el comportamiento fiscal del Estado, lo cual tiene un impacto directo sobre el consumo, la inversión y los precios en la economía (SEFIN, 2018).

El Acuerdo Monetario Centroamericano es clave en la integración regional de los países centroamericanos, orientado hacia la coordinación y armonización de políticas macroeconómicas, monetarias, crediticias y cambiarias. A través de la armonización de las legislaciones monetarias y crediticias, así como la supervisión colaborativa de los mercados de capitales, se busca asegurar un entorno financiero estable y cooperativo que permita a los Estados centroamericanos enfrentar desafíos económicos de manera conjunta y eficaz (SECMCA, 2019).

La Ley de Protección al Consumidor de Honduras tiene como objetivo garantizar los derechos de los consumidores, regulando las relaciones de consumo en el mercado de bienes y servicios. Establece los derechos y obligaciones de los consumidores y proveedores, así como los procedimientos, infracciones y sanciones correspondientes (La Gaceta, 2008).

La Ley para la Defensa y Promoción de la Competencia tiene como objetivo fomentar y proteger la libre competencia para asegurar el funcionamiento eficiente del mercado y promover el bienestar de los consumidores (La Gaceta, 2006).

CAPÍTULO III. METODOLOGÍA

3.1 CONGRUENCIA METODOLÓGICA

Este capítulo presenta el marco teórico que sustenta la investigación y expone la metodología aplicada, incluyendo el enfoque, los métodos, y el diseño de investigación. Además, se definen la población y muestra para el análisis, junto con las técnicas e instrumentos empleados, y las fuentes de información que respaldaron el desarrollo de este estudio.

3.1.1 MATRIZ METODOLÓGICA

La matriz metodológica es una herramienta fundamental en el desarrollo de una investigación, ya que permite estructurar de manera clara y sistemática los elementos esenciales del estudio. Su función principal es facilitar la organización y el diseño metodológico, garantizando la coherencia entre los objetivos específicos, las variables, sus dimensiones e indicadores, así como los métodos y técnicas de recolección y análisis de datos.

Esta matriz no solo contribuye a establecer una secuencia lógica en el proceso investigativo, sino que también permite visualizar de manera integral la relación entre los diferentes componentes del estudio. Al alinear los objetivos específicos con las variables, se asegura que cada aspecto del análisis tenga un sustento teórico y metodológico adecuado, lo que fortalece la validez y fiabilidad de los resultados obtenidos.

A continuación, se presenta la matriz metodológica que guía de manera eficiente la investigación (ver Tabla 1), proporcionando una base estructurada para el desarrollo del estudio y la obtención de conclusiones fundamentadas.

Tabla 1. Matriz de congruencia metodológica

Título: Análisis y Estimación de la Inflación en Honduras Mediante Redes Neuronales Análisis y Estimación de la Inflación en Honduras Mediante Redes Neuronales Artificiales de mayo 2005 a junio 2024							
Problema	Preguntas de investigación	Objetivo General	Objetivos Específicos	Metodología	Herramientas	Variables Independiente	Variable Dependiente
¿Cómo se puede desarrollar la propuesta de un modelo basado en redes neuronales que permita predecir la inflación mensual de manera más robusta y precisa, considerando la interacción no lineal de las variables macroeconómicas y microeconómicas clave?	¿Cuáles son los factores clave que impulsan la inflación en Honduras?	Desarrollar la propuesta de un modelo basado en redes neuronales para predecir la inflación mensual en Honduras, analizando los factores macroeconómicos y microeconómicos que influyen en este fenómeno, con el fin de proporcionar pronósticos más precisos y útiles para la toma de decisiones económicas	Identificar y analizar los factores clave que impulsan la inflación en Honduras, considerando tanto variables macroeconómicas como microeconómicas, para comprender su impacto en el fenómeno inflacionario	Minería de datos y Modelos Predictivos	Excel	1. Sector Monetario/ Financiero	Inflación
	¿Qué precisión pueden alcanzar los modelos de redes neuronales en la predicción de la inflación mensual en Honduras?		Evaluar la precisión de los modelos de redes neuronales en la predicción de la inflación mensual en Honduras, mediante la comparación de sus resultados con los de modelos tradicionales de pronóstico.				
	¿Cómo se pueden optimizar las redes neuronales para maximizar su rendimiento en la predicción de la inflación mensual?						

Continuación de la Tabla 1. Matriz de congruencia metodológica

Título: Análisis y Estimación de la Inflación en Honduras Mediante Redes Neuronales Análisis y Estimación de la Inflación en Honduras Mediante Redes Neuronales Artificiales de mayo 2005 a junio 2024							
Problema	Preguntas de investigación	Objetivo General	Objetivos Específicos	Metodología	Herramientas	VARIABLES Independiente	Variable Dependiente
	¿Es posible elaborar una propuesta para la implementación de un algoritmo basado en redes neuronales para predecir la inflación en Honduras?		<p>Optimizar las redes neuronales para maximizar su rendimiento en la predicción de la inflación mensual, identificando las configuraciones y técnicas que mejoren su capacidad de captar la interacción no lineal de las variables involucradas.</p> <p>Elaborar una propuesta para la implementación de un algoritmo de redes neuronales que permita la predicción de la inflación en Honduras, evaluando su viabilidad y el impacto potencial en la precisión de los pronósticos económicos del país.</p>				

Fuente: Elaboración Propia

3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO

En este apartado se detallan las variables y la relación que existe entre ellas. A continuación, en la Figura 12, se presenta un resumen visual de las conexiones entre las variables utilizadas en esta investigación.

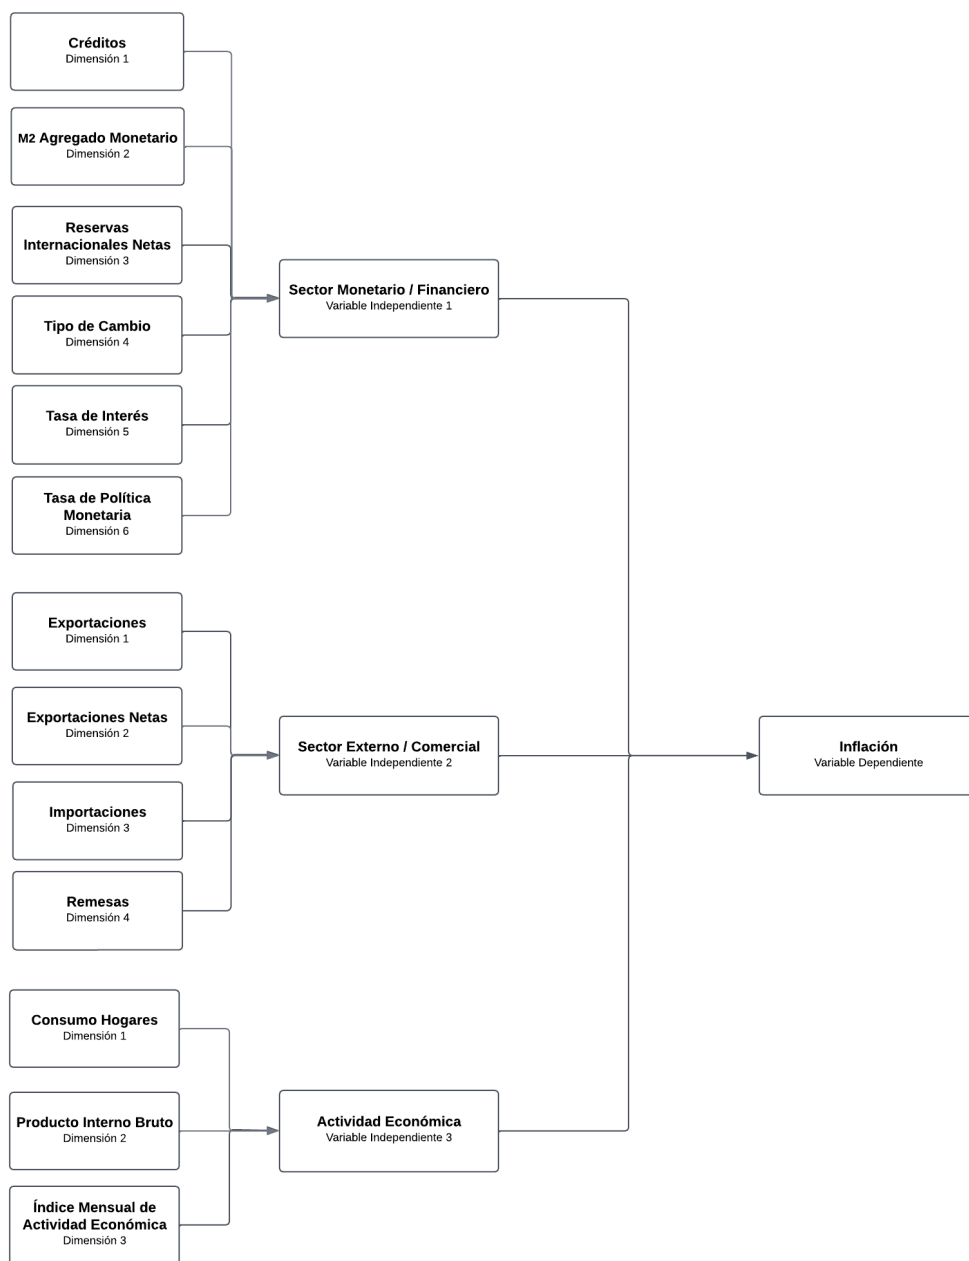


Figura 12. Diagrama de variables

Fuente: Elaboración propia

3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES

A continuación, se presenta una tabla que muestra la operacionalización de las variables que se emplearán en esta investigación.

Tabla 2. Operacionalización de variable dependiente

Variable	Descripción Conceptual	Descripción operacional	Dimensión	Ítems
Inflación	La inflación se define como un incremento sostenido y generalizado en los precios de productos y servicios dentro de una economía. Esta métrica es fundamental para analizar la evolución del costo de vida y su impacto sobre el poder adquisitivo de las familias (Gutiérrez Andrade y Zurita Moreno, 2006).	Esta variable se define mediante el cálculo del Índice de Precios al Consumidor (IPC), que refleja las variaciones en los precios de una canasta representativa de bienes y servicios durante periodos específicos.	Índice de Precios al Consumidor (IPC)	Variaciones porcentuales mensuales

Fuente: Elaboración propia

Tabla 3. Operacionalización de variables independientes

Variable	Descripción Conceptual	Descripción operacional	Dimensión	Ítems
Sector Monetario/ Financiero	Según el Banco Central del Ecuador (2015), el sector monetario y financiero abarca todas las transacciones relacionadas con la administración del dinero, los servicios bancarios, y las políticas monetarias establecidas por las instituciones financieras de una nación. Este sector permite la fluidez del capital entre ahorradores e	Se deben cuantificar indicadores clave como el costo de las inversiones, los flujos de ingresos y gastos, y las tasas de interés, lo cual permitirá calcular el punto de equilibrio y evaluar la viabilidad del proyecto. También es fundamental considerar la política monetaria y el tipo de cambio, así como las reservas internacionales netas.	Crédito	Millones de moneda nacional
			M2 Agregado Monetario	Número de veces
			Reservas Internacionales Netas	Millones de US dólares.
			Tipo de Cambio	Moneda nacional por unidad de US dólar

Continuación de la Tabla 3. Operacionalización de variables independientes

Variable	Descripción Conceptual	Descripción operacional	Dimensión	Ítems
	inversionistas, lo que contribuye a la estabilidad económica y al control de factores como la inflación y las tasas de interés	Estos indicadores financieros son esenciales para tomar decisiones estratégicas sobre el inicio, ajuste o replanteamiento de proyectos financieros	Tasa de Interés	Porcentajes
			Tasa de Política Monetaria	Porcentajes
Sector Externo/Comercial	La viabilidad comercial de una economía se manifiesta en la capacidad de interactuar efectivamente con mercados internacionales, facilitando así el intercambio de bienes, servicios, e inversiones. Según el Banco Central del Ecuador (2012), el sector externo representa las transacciones económicas con otros países, englobando importaciones, exportaciones y la gestión de transferencias y remesas, lo cual impacta de manera significativa en la balanza de pagos y la posición comercial de una nación.	En este sector, se identifican las demandas de productos y servicios en los mercados internacionales y se miden indicadores de competitividad, calidad, y consumo. Esto permite definir estrategias comerciales como precios, publicidad y comunicación, así como evaluar las condiciones de pago y los costos de distribución. Para optimizar la colocación de productos, es clave establecer canales de distribución eficaces y analizar la logística necesaria para alcanzar los consumidores de manera eficiente.	Exportaciones	Millones de US dólares
			Exportaciones Netas	Millones de US dólares
			Importaciones	Millones de US dólares
			Remesas	Millones de US dólares.
Actividad Económica	La actividad económica, según el Instituto Nacional de Estadística e Informática (2018), se refiere a la generación de valor a través de la producción de bienes y servicios que responden a las necesidades de la sociedad.	Para medir la actividad económica, se utilizan indicadores como el consumo de los hogares, el Producto Interno Bruto (PIB) y el Índice Mensual de Actividad Económica (IMAE).	Consumo Hogares	Porcentaje del crecimiento anual

Continuación de la Tabla 3. Operacionalización de variables independientes

Variable	Descripción Conceptual	Descripción operacional	Dimensión	Ítems
Actividad Económica	Este proceso incluye la extracción, transformación y comercialización de recursos para fomentar el crecimiento económico y la generación de riqueza.	Estos indicadores permiten monitorear el desempeño de la economía, identificar patrones y tendencias, y formular políticas efectivas. La cuantificación de estos factores permite evaluar la salud económica de un país y establecer estrategias para su desarrollo sostenible.	Índice Mensual de Actividad Económica Producto Interno Bruto	Variaciones en porcentajes
			Producto Interno Bruto	Millones de moneda nacional

Fuente: Elaboración propia

3.1.4 HIPÓTESIS

Hipótesis Nula (H₀):

Los modelos tradicionales de predicción de la inflación, que no consideran la no linealidad y la complejidad de las interacciones entre factores macroeconómicos y microeconómicos, ofrecen la misma precisión en la predicción de la inflación mensual en Honduras que un modelo basado en redes neuronales.

Hipótesis Alternativa (H₁):

Un modelo basado en redes neuronales, que captura la interacción no lineal de variables macroeconómicas y microeconómicas, proporciona una mayor precisión en la predicción de la inflación mensual en Honduras en comparación con los métodos tradicionales.

Estas hipótesis permiten establecer un marco claro para evaluar la eficacia de las redes neuronales en comparación con los métodos tradicionales, y son coherentes con el objetivo de demostrar la viabilidad y utilidad del modelo propuesto en tu investigación.

3.2 ENFOQUE Y MÉTODOS

El enfoque de la investigación se refiere a la perspectiva general que orienta el diseño del estudio, estableciendo su naturaleza y alcance. Este enfoque determina si la investigación será cualitativa, cuantitativa o mixta, según el tipo de conocimiento que se busca obtener. Por su parte, los métodos de investigación comprenden las técnicas específicas empleadas para la recolección y análisis de datos en el contexto del estudio, tales como encuestas, entrevistas, análisis estadísticos o modelado predictivo, cada uno seleccionado según la necesidad de responder a las preguntas de investigación planteadas (Hernández Sampieri, 2010).

La Figura 13 resume las definiciones contenidas en esta sección.

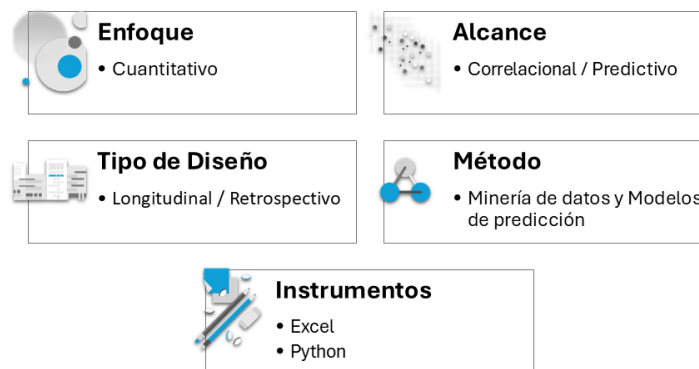


Figura 13. Enfoque y Métodos

Fuente: Elaboración propia

3.2.1 ENFOQUE

La presente investigación adopta un enfoque cuantitativo, centrado en la recopilación y análisis de datos numéricos sobre variables macroeconómicas y microeconómicas que inciden en la inflación en Honduras. Este enfoque cuantitativo permite evaluar con rigurosidad la precisión y efectividad del modelo de redes neuronales propuesto, en comparación con los métodos tradicionales de pronóstico, contribuyendo así a una comprensión más profunda de los factores inflacionarios y a la mejora de las herramientas predictivas utilizadas en el ámbito económico.

3.2.2 ALCANCE

El alcance de la investigación es tanto correlacional como predictivo. En el ámbito correlacional, se identifican y analizan los factores clave que influyen en la inflación en Honduras, explorando la relación específica entre cada variable y este fenómeno. Desde una perspectiva predictiva, se desarrolla y evalúa un modelo basado en redes neuronales, diseñado para anticipar la inflación mensual con mayor precisión, proporcionando herramientas valiosas para la toma de decisiones económicas en el país.

3.2.3 DISEÑO

El diseño de la investigación es longitudinal y retrospectiva. Se considera longitudinal porque utiliza una serie temporal de datos que abarca un período específico, con el objetivo de identificar tendencias y patrones que influyen en la inflación. Asimismo, es retrospectivo debido a que se analizan datos históricos de manera observacional, sin manipular intencionalmente las variables. El análisis se centra en evaluar la eficacia de un modelo basado en redes neuronales en comparación con modelos tradicionales para predecir la inflación mensual a lo largo del tiempo.

3.2.4 MÉTODO

El método aplicado en esta investigación combina la minería de datos para el análisis exploratorio (EDA) y la construcción de modelos predictivos. El proceso comienza con la recopilación de datos históricos relevantes sobre variables relacionadas con la inflación en Honduras. A continuación, se lleva a cabo el preprocesamiento de los datos, seguido de la construcción, entrenamiento y validación del modelo utilizando técnicas de machine learning. Finalmente, se compara el rendimiento del modelo predictivo con métodos tradicionales.

3.2.5 INSTRUMENTOS

En esta investigación, se utilizan herramientas clave para la recopilación, gestión y análisis de datos. El conjunto de datos abarca el período de mayo 2005 a junio de 2024 y proviene de fuentes confiables como el Banco Central de Honduras (BCH), la Comisión Nacional de Bancos y Seguros (CNBS), la Secretaría Ejecutiva del Consejo Monetario Centroamericano (SECMCA) y el Banco Mundial. Estos datos se importan y organizan

utilizando Microsoft Excel, lo que facilita la creación de un dataset limpio y estructurado. Posteriormente, para el análisis más avanzado y el desarrollo de modelos predictivos, se emplea Python, que proporciona potentes herramientas de machine learning para el procesamiento y modelado de los datos.

3.3 DISEÑO DE LA INVESTIGACIÓN

En el contexto de la predicción de la inflación en Honduras, se llevó a cabo un estudio observacional retrospectivo. Este diseño se seleccionó con el objetivo de aprovechar datos históricos existentes sobre variables macroeconómicas y microeconómicas clave que afectaron la inflación en el país. El enfoque permitió identificar patrones y relaciones en los datos históricos, contribuyendo a la precisión de las predicciones futuras sobre la inflación mensual y proporcionando información valiosa para la toma de decisiones económicas.

3.3.1 POBLACIÓN

La población de estudio está compuesta por series de datos mensuales que abarca desde el año 1990 hasta junio de 2024. Estos datos incluyen variables macroeconómicas y microeconómicas relevantes para el análisis de la inflación en Honduras, las cuales son fundamentales para entender los factores que inciden en el comportamiento de los precios en el país. Las fuentes de extracción de estos datos incluyen:

1. Banco Central de Honduras (BCH): Se utilizan datos sobre el índice de precios al consumidor (IPC), reservas internacionales netas, índice de actividad económica, tipo de cambio, tasas de interés, remesas y la tasa de política monetaria, que son indicadores esenciales para analizar la inflación y su relación con el contexto económico nacional e internacional.
2. Comisión Nacional de Bancos y Seguros (CNBS): Se extraen datos relacionados con créditos otorgados por el sistema financiero.
3. Secretaria Ejecutiva del Consejo Monetario Centroamericano (SECMCA): Se recopilan datos sobre exportaciones e importaciones, variables que afectan directamente la balanza comercial y la oferta y demanda de productos, lo que influye en los precios internos del país.

4. Banco Mundial: Se recopilan y analizan datos relacionados con el gasto de consumo final de los hogares en Honduras, proporcionados por esta institución. Estos datos ofrecen una visión integral sobre los patrones de consumo y son fundamentales para evaluar la dinámica económica del país

3.3.2 MUESTRA

La muestra se toma a partir de mayo del año 2005 hasta junio de 2024, resultando en un total de 230 observaciones. Este conjunto de datos proporciona la base para el análisis y la construcción de modelos predictivos sobre la inflación mensual en Honduras.

3.3.3 TÉCNICAS DE MUESTREO

En esta investigación se ha optado por un muestreo no probabilístico por conveniencia, ya que la selección de la muestra está basada en la disponibilidad de datos relevantes que cubren eventos económicos significativos. La decisión de utilizar este tipo de muestreo responde a la necesidad de analizar períodos históricos clave que han tenido un impacto considerable en la economía hondureña y mundial.

La muestra se ha diseñado para abarcar eventos trascendentales que influyen en la dinámica inflacionaria. Entre estos eventos se incluyen la crisis financiera global de 2008, que tuvo sus raíces en el colapso del mercado inmobiliario en Estados Unidos y provocó una recesión económica a nivel mundial, afectando a diversos sectores y generando secuelas a largo plazo (Rosenthal, 2010). Además, se consideran eventos nacionales relevantes, como el golpe de Estado en Honduras en 2009, que tuvo repercusiones económicas y sociales significativas en el país. Por último, la muestra también abarca la pandemia de COVID-19 en el año 2020, un evento global que impactó profundamente la economía y alteró la dinámica de los mercados internacionales y locales.

3.4 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS

3.4.1 TÉCNICAS

En la presente investigación, se emplearon técnicas avanzadas para el análisis de los datos económicos, específicamente Minería de Datos y Modelos Predictivos. Estas técnicas fueron esenciales para descubrir patrones, relaciones y realizar predicciones precisas a partir de los datos recopilados.

3.4.1.1 MINERÍA DE DATOS

En esta investigación, la minería de datos se utilizó principalmente para explorar las variables, detectar tendencias y analizar correlaciones que pudieron influir en la inflación.

3.4.1.2 MODELOS PREDICTIVOS

Para esta investigación, se probaron dos tipos principales de modelos predictivos:

- Redes Neuronales Artificiales
- Modelos de Series Temporales

3.4.2 INSTRUMENTOS

Para esta investigación, se utilizaron dos herramientas principales: Microsoft Excel y Python. Estas herramientas facilitaron tanto la organización de los datos como el análisis avanzado, permitiendo la construcción de un modelo de predicción preciso para la estimación de la inflación en Honduras.

3.4.2.1 MICROSOFT EXCEL

Microsoft Excel se utilizó principalmente para la importación, organización y almacenamiento de los datos recopilados.

3.4.2.2 PYTHON

Python se utilizó para llevar a cabo el análisis avanzado de los datos y el desarrollo de modelos de aprendizaje automático. Se emplearon bibliotecas como TensorFlow y PyTorch para la creación, implementación y entrenamiento de los modelos.

3.4.3 PROCEDIMIENTOS

El proceso de investigación constó de los siguientes pasos:

- Recopilación y Preparación de Datos: Se recopilaron datos relevantes para la inflación mensual en Honduras de fuentes primarias. Posteriormente, se realizó un análisis exhaustivo de las variables disponibles, identificando aquellas que tuvieron un impacto significativo en la inflación mensual y descartando aquellas que no fueron relevantes.

- **Diseño y Entrenamiento de Modelos:** Se diseñaron y entrenaron varios modelos de redes neuronales utilizando diferentes arquitecturas y parámetros. Se emplearon una variedad de técnicas de optimización y regularización para mejorar el rendimiento y evitar el sobreajuste de los modelos.
- **Evaluación del Rendimiento del Modelo:** Se realizó una evaluación exhaustiva del rendimiento de los modelos utilizando métricas de evaluación adecuadas, como el error cuadrático medio (MSE) o el coeficiente de determinación (R²). Se utilizó la validación cruzada temporal para evaluar la capacidad de generalización de los modelos en datos no vistos.
- **Análisis de Resultados y Ajustes:** Se analizaron los resultados obtenidos y se realizaron ajustes en los modelos según fuera necesario para mejorar su precisión en la predicción de la inflación mensual en Honduras. Se documentaron los hallazgos y las lecciones aprendidas durante el proceso de investigación.

3.5 FUENTES DE INFORMACIÓN

En el marco de esta investigación, es esencial reconocer la diferencia entre fuentes primarias y secundarias, ya que cada tipo de fuente aporta un valor distinto al análisis. Las fuentes primarias proporcionan datos directos y no procesados, obtenidos de manera original y directa para responder a una pregunta de investigación específica. Son el punto de partida fundamental en el proceso investigativo, ya que ofrecen información sin haber sido filtrada ni interpretada previamente. En contraste, las fuentes secundarias consisten en información que ha sido recopilada, reorganizada o analizada por otros, lo que facilita el acceso y la interpretación de los datos, pero no constituye la base original (Life Pacific University, 2023).

3.5.1 FUENTES PRIMARIAS

En esta investigación, las fuentes primarias corresponden a aquellos datos originales y no procesados que se recopilan directamente desde las fuentes de información relevantes. Aunque los datos provistos por instituciones como el Banco Central de Honduras (BCH), la Comisión Nacional de Bancos y Seguros (CNBS), la Secretaría Ejecutiva del Consejo Monetario Centroamericano (SECMCA) y Banco Mundial están organizados y estructurados para su distribución pública, se consideran fuentes primarias porque son generados

directamente por estas entidades oficiales, sin ser procesados.

3.5.2 FUENTES SECUNDARIAS

Las fuentes secundarias corresponden a aquellos datos y materiales que han sido previamente procesados, analizados e interpretados por otros autores o instituciones. En esta investigación, las fuentes secundarias incluyen libros, revistas científicas, tesis, informes y otros documentos académicos que han sido utilizados para construir el marco teórico. Estas fuentes proporcionan una base de conocimiento previamente validado y permiten contextualizar la investigación dentro del panorama global y local sobre la temática estudiada. A través de la revisión de estos materiales, se ha podido identificar teorías, modelos y enfoques metodológicos relevantes que han sido aplicados en estudios previos sobre la inflación y el uso de redes neuronales en la predicción económica.

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

En este capítulo, se presentan y analizan los resultados obtenidos, en relación con los objetivos establecidos en el planteamiento del problema y las preguntas de investigación. Además, se lleva a cabo una evaluación de los datos para situar los resultados en un contexto más amplio. El propósito principal de este capítulo es exponer los hallazgos de manera clara y estructurada.

4.1 INFORME DE PROCESO DE RECOLECCIÓN DE DATOS

El proceso de recopilación de datos se llevó a cabo de manera sistemática, siguiendo los siguientes pasos:

1. Acceso a las Fuentes Oficiales

Se identificaron las fuentes oficiales que proporcionan los datos relevantes para el análisis de la inflación en Honduras, tales como:

- Banco Central de Honduras (BCH)
- Comisión Nacional de Bancos y Seguros (CNBS)
- Secretaria Ejecutiva del Consejo Monetario Centroamericano (SECMCA)
- Banco Mundial

2. Selección de las Variables y su Periodo Específico

Para cada fuente, se eligieron las variables clave necesarias para el análisis de la inflación. Además, se filtró el periodo de tiempo correspondiente, que abarca desde mayo de 2005 hasta junio de 2024, y se seleccionó la métrica adecuada (mensual, trimestral o interanual), según lo requerido para el estudio y disponibilidad.

3. Descarga de Datos

Desde las páginas oficiales de cada fuente, se descargaron las series de datos correspondientes a las variables de interés en formato Excel (.csv). Las variables obtenidas incluyeron:

- Banco Central de Honduras (BCH): Índice de precios al consumidor (IPC), reservas internacionales netas, índice de actividad económica, tipo de cambio, tasas de interés las cuales se dividen en tasa de interés activa y tasa de interés pasiva, remesas y tasa de política monetaria.
- Comisión Nacional de Bancos y Seguros (CNBS): Datos sobre créditos otorgados por el sistema financiero.
- Secretaria Ejecutiva del Consejo Monetario Centroamericano (SECMCA): Información sobre exportaciones, exportaciones netas e importaciones, que impactan la balanza comercial y la oferta y demanda de productos, influyendo directamente en los precios internos. Así como la relación del agregado monetario M2 a la base monetaria amplia.
- Banco Mundial: Consumo de Hogares.

4. Unificación de los Datos

Una vez descargados los archivos en formato CSV, se unificaron todas las variables en una sola hoja de trabajo de Excel. Se prestó especial atención a la secuencia lógica de los datos mensuales, asegurando que las fechas se alinearan correctamente y que los valores de las variables estuvieran en el formato adecuado para su posterior análisis.

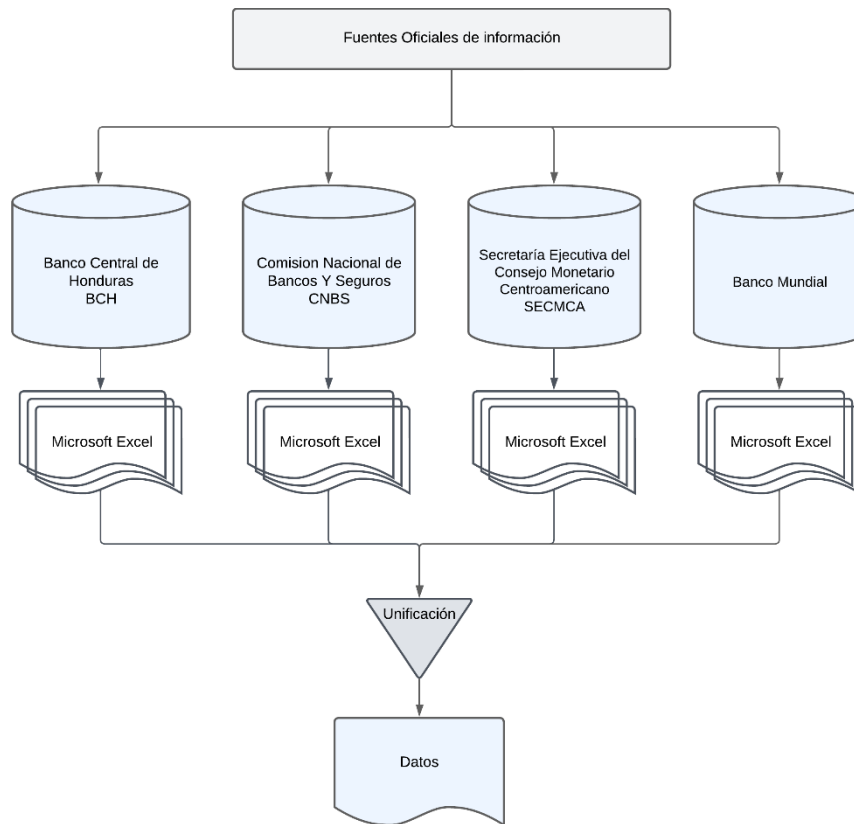


Figura 14. Recolección de datos

Fuente: Elaboración propia.

La base de datos resultante está compuesta por 18 variables y 230 registros

```

[230 rows x 18 columns]>
Fecha                               datetime64[ns]
TPM                                  float64
TA                                   float64
TP                                   float64
IPC variación interanual             float64
IMAE                                 float64
IMAE, variación interanual           float64
PIB trimestral                       float64
PIB trimestral variación interanual  float64
Tipo Cambio                          float64
Remesas                              float64
Credito Total                        float64
Reservas Internacionales              float64
Exportaciones                        float64
Importaciones                        float64
Exportaciones Netas                  float64
M2 Agregado Monetario                float64
Consumo Hogares                      float64
dtype: object
Cantidad de registros: 230
  
```

Figura 15. Datos

Fuente: Elaboración propia.

4.2 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS

En este capítulo se presentan los principales hallazgos derivados de la investigación, resultado del análisis detallado de la información recopilada. Este proceso permitió identificar patrones relevantes y obtener una visión inicial del comportamiento de los datos, lo cual sirvió como base para implementar los modelos seleccionados. Los resultados obtenidos reflejan la efectividad de los enfoques aplicados y aportan elementos clave para comprender el fenómeno inflacionario en Honduras.

4.2.1 FACTORES CLAVE QUE IMPULSAN LA INFLACIÓN EN HONDURAS

En esta sección, se comienza con el análisis descriptivo de la inflación en Honduras, explorando su distribución y estacionalidad. Posteriormente, se examina la relación entre las variables independientes con la inflación, con el objetivo de identificar patrones que permitan predecir la inflación en el contexto económico del país.

4.2.1.1 ESTADÍSTICOS DESCRIPTIVOS DE LA INFLACIÓN

El comportamiento de la Variación Interanual del IPC en Honduras refleja momentos clave de la historia económica y social del país. En 2008, el IPC alcanzó su valor máximo de 13.99%, lo cual estuvo estrechamente relacionado con la crisis económica global que afectó a muchas economías emergentes. Esta crisis fue desencadenada por el colapso de los mercados financieros internacionales, lo que provocó un aumento significativo de los precios de los productos básicos y una fuerte presión inflacionaria. Este periodo también coincidió con una inestabilidad política interna debido al golpe de estado ocurrido en junio de 2009, lo que agravó aún más las dificultades económicas del país.

Por otro lado, el comportamiento del IPC en 2020 reflejó los efectos devastadores de la pandemia de COVID-19, que generó una profunda crisis económica a nivel global. Durante este año, la incertidumbre en los mercados y las alteraciones en la oferta y demanda de bienes y servicios provocaron un comportamiento atípico del IPC. Aunque el confinamiento y las restricciones impulsaron una caída en algunos precios, la crisis sanitaria y las medidas adoptadas para controlar la pandemia también impactaron negativamente en la economía, generando fluctuaciones en los precios de productos esenciales y servicios.

Estos eventos históricos y sus efectos en la economía se reflejan en las variaciones del IPC a lo largo de los años, donde se observa cómo eventos externos e internos han influido en la inflación en el país, destacando los picos de 2008 y 2020 como momentos críticos en la economía de Honduras.




Figura 16. Comportamiento del IPC Variación Interanual

Fuente: Elaboración propia.

Las métricas estadísticas calculadas para la variación interanual del Índice de Precios al Consumidor (IPC) son esenciales para entender su comportamiento a lo largo del tiempo. La media se ubica en 5.63%, lo que indica el valor promedio del IPC durante el período analizado. La mediana, con un valor de 5.02%, refleja el punto central de los datos, mientras que la moda, que es de 3.84%, representa el valor más frecuente. Además, la desviación estándar de 2.35% muestra el grado de dispersión o variabilidad en torno a la media, lo que permite evaluar la estabilidad de los cambios en el IPC a lo largo del tiempo.

4.2.1.2 DISTRIBUCIÓN Y ESTACIONALIDAD DE LA INFLACIÓN

La distribución de la variación interanual del Índice de Precios al Consumidor (IPC) presentada en el histograma refleja una tendencia asimétrica, con una concentración notable de los valores en torno a los rangos bajos, entre 2% y 6%. Este patrón indica que la mayoría de las observaciones se encuentran dentro de este intervalo, lo que sugiere una variabilidad moderada en la inflación durante el período analizado. La curva de densidad superpuesta muestra una distribución con una forma ligeramente sesgada hacia la derecha, lo que implica que existen algunos valores extremos que superan los 10%, aunque con menor frecuencia. Este análisis destaca una distribución de frecuencias que no es completamente simétrica, lo que podría tener implicaciones importantes para la interpretación de las fluctuaciones en los

precios.





Figura 17. Distribución del IPC Variación Interanual

Fuente: Elaboración propia

La variación interanual del Índice de Precios al Consumidor (IPC) presenta una serie temporal con fluctuaciones significativas, destacándose picos pronunciados alrededor de los años 2007 y 2022. Estos picos sugieren momentos de alta inflación, seguidos de caídas abruptas. La prueba de raíz unitaria ADF (Augmented Dickey-Fuller) aplicada a los datos muestra un valor estadístico de -2.4963 , acompañado de un valor p de 0.1164 , lo que indica que no se puede rechazar la hipótesis nula de no estacionariedad a un nivel de significancia del 5%. Además, los valores críticos para los niveles del 1%, 5% y 10% están por debajo del estadístico ADF, lo que refuerza la conclusión de que la serie no es estacionaria.

Este resultado sugiere que es necesario realizar un proceso de diferenciación o transformación de los datos para estabilizar la varianza y permitir un análisis más robusto de la tendencia patrones subyacentes en la variación del IPC.




Estadístico ADF: -2.4962657945261193
 Valor p: 0.11638554304888016
 Número de retardos utilizados: 13
 Número de observaciones utilizadas para la prueba: 216
 Valores críticos:
 1%: -3.4609922013325267
 5%: -2.875015740963014
 10%: -2.5739524288408777
 La serie NO es estacionaria.

Figura 18. Estacional de la serie IPC Variación Interanual

Fuente: Elaboración propia

El análisis de la primera diferencia del Índice de Precios al Consumidor (IPC) utilizando la prueba de raíz unitaria ADF (Augmented Dickey-Fuller) arroja un estadístico ADF de -5.468, lo cual es significativamente más bajo que los valores críticos a los niveles de significancia del 1%, 5% y 10%, que son -3.461, -2.875 y -2.574, respectivamente. El valor p es de 2.43×10^{-6} , lo que indica una fuerte evidencia en contra de la hipótesis nula de no estacionariedad. Con base en estos resultados, se concluye que la serie es estacionaria, lo que sugiere que no presenta una raíz unitaria y que sus propiedades estadísticas no cambian con el tiempo.



Estadístico ADF: -5.468208123175202
 Valor p: 2.4317801070067023e-06
 Número de retardos utilizados: 12
 Número de observaciones utilizadas para la prueba: 216
 Valores críticos:
 1%: -3.4609922013325267
 5%: -2.875015740963014
 10%: -2.5739524288408777
 La serie es estacionaria.

Figura 19. Diferenciado IPC Variación Interanual

Fuente: Elaboración propia

4.2.1.3 ANÁLISIS DE LA RELACIÓN ENTRE LAS VARIABLES INDEPENDIENTES Y LA INFLACIÓN

a. ANÁLISIS CORRELACIONAL

En el proceso de construcción de un modelo econométrico para la predicción de la inflación, es fundamental evaluar la correlación entre las variables independientes y la variable dependiente, así como las interrelaciones entre las propias variables independientes. Un análisis detallado de las correlaciones ayuda a identificar posibles problemas de multicolinealidad, que pueden comprometer la estabilidad y la precisión de las estimaciones del modelo. A continuación, se presenta un análisis centrado en las variables correlacionadas con el Índice de Precios al Consumidor (IPC) y aquellas que presentan una alta correlación entre sí, con el objetivo de identificar aquellas que deberían ser eliminadas para mitigar los efectos de la multicolinealidad.

- Tasa de interés activa (TA) y M2 Agregado Monetario: La correlación entre estas variables y el IPC es moderada (0.3), lo que indica que existe una relación positiva, aunque no muy fuerte.
- TPM: La correlación entre la TPM y el IPC es moderada (0.2), lo que indica que existe una relación positiva, aunque no muy fuerte.
- IMAE variación interanual, PIB variación interanual y Consumo Hogares: La correlación entre estas variables y el IPC es débil (0.1), lo que indica que existe una relación positiva.
- Tasa Pasiva (TP), Remesas e importaciones: La correlación entre estas y el IPC es muy baja (casi nula, 0.0). Este hallazgo sugiere que no existe una relación significativa entre estas variables y el IPC.
- Tipo de Cambio y las Exportaciones Netas: La correlación entre estas variables y el IPC es moderada (-0.3), lo que indica que existe una relación negativa, aunque no muy fuerte.
- Crédito Total, IMAE y PIB trimestral: La correlación entre estas variables y el IPC es de -0.2, lo que refleja una relación negativa débil.
- Reservas internacionales Netas y Exportaciones: La correlación entre estas variables y el IPC es de -0.1, lo que refleja una relación negativa débil.
- Tipo de Cambio, Remesas, Crédito Total y Reservas Internacionales: Estas tres variables presentan una correlación extremadamente alta (rango de 0.9 a 1.0), lo que sugiere que están capturando la misma información en términos de flujos de capital y estabilidad financiera. La inclusión de todas ellas en el modelo sería redundante, lo que podría distorsionar los resultados y afectar la interpretación de los coeficientes.
- Exportaciones e Importaciones: La correlación entre estas dos variables es igualmente alta (0.9), lo que implica que ambas variables están fuertemente relacionadas.
- IMAE, IMAE, variación interanual, PIB Trimestral y PIB Trimestral Variación Interanual: Estas cuatro variables presentan una correlación extremadamente alta (rango de 0.9 a 1.0), lo que indica que están reflejando esencialmente el mismo comportamiento en términos de la actividad económica. Incluir todas estas variables

en el modelo no aportaría información significativamente nueva y generaría multicolinealidad.




Figura 20. Matriz de Correlación

Fuente: Elaboración propia

Se ha implementado un modelo de regresión lineal múltiple con el propósito de analizar y explicar la variación interanual del Índice de Precios al Consumidor (IPC) en función de diversas variables económicas. La estimación del modelo se realizó utilizando el método de Mínimos Cuadrados Ordinarios (OLS), lo que permitió identificar los factores clave que influyen en la evolución de los precios a nivel nacional. Adicionalmente, se evaluó el R-cuadrado ajustado para respaldar la capacidad predictiva del modelo. Este análisis proporciona una herramienta esencial para comprender los determinantes del IPC.

Es importante destacar que este modelo se ha vinculado con el análisis de la matriz de correlación, lo que ofrece una base sólida para identificar las variables más relevantes en el fenómeno inflacionario. Cabe aclarar que, en esta etapa, el objetivo principal del modelo no es realizar pronósticos, sino más bien establecer una comprensión detallada de los factores que inciden en la dinámica del IPC.

Los resultados obtenidos del modelo de regresión lineal múltiple muestran un R-cuadrado ajustado de 0.744, lo que indica que el 74.4% de la variabilidad en la variable dependiente, la variación interanual del Índice de Precios al Consumidor (IPC), puede ser explicada por las variables independientes incluidas en el modelo.

En cuanto a la significancia de las variables, aquellas con un valor p menor a 0.05 se consideran estadísticamente significativas. Entre ellas destacan: la Tasa de Política Monetaria (TPM), la Tasa Activa (TA), la Tasa Pasiva (TP), las Exportaciones Netas, las Importaciones y las Reservas Internacionales Netas, todas con un valor p de 0.000. Por otro lado, las variables como el Índice Mensual de Actividad Económica (IMAE) variación interanual, el Crédito Total, el Tipo de Cambio y las Exportaciones también presentan valores p significativos, con valores de 0.003, 0.001, 0.001 y 0.004, respectivamente. Las demás variables presentan valores p superiores a 0.05, lo que sugiere que no son estadísticamente significativas en este modelo. Anexo 1

Tras el análisis realizado, se han seleccionado las variables más relevantes para explicar la variación interanual del Índice de Precios al Consumidor (IPC), considerando su importancia estadística y su relación con la inflación. Las variables elegidas son la Tasa de Política Monetaria (TPM), la Tasa Activa (TA), el Índice Mensual de Actividad Económica (IMAE) en su variación interanual, el Tipo de Cambio, las Exportaciones, el M2 Agregado Monetario y el Consumo de Hogares. Las correlaciones respectivas de estas variables con el IPC son de 0.23, 0.28, 0.12, -0.33, -0.33, 0.29 y 0.061, lo que refleja tanto relaciones directas como inversas de distinta magnitud. Este conjunto de variables proporciona una base sólida para analizar los determinantes del fenómeno inflacionario, garantizando la inclusión de factores clave y minimizando los riesgos asociados a la multicolinealidad en el modelo.




Figura 21. Matriz de Correlación Limpia

Fuente: Elaboración propia

b. DISTRIBUCIÓN DE LAS VARIABLES INDEPENDIENTES

Para comprender mejor los factores que inciden en la inflación, es crucial analizar las distribuciones de las variables independientes o exógenas que pueden influir directamente en su comportamiento. Estas variables representan diferentes aspectos de la economía y su interacción permite capturar las dinámicas subyacentes en el fenómeno inflacionario. A continuación, se presentan las distribuciones de cada una de estas variables clave:

- Distribución de la Tasa de Política Monetaria (TPM)

La TPM muestra una distribución bimodal, lo que indica que ha tendido a concentrarse en dos niveles principales durante el período analizado. Esto podría reflejar la implementación de políticas monetarias diferenciadas en

respuesta a distintos contextos económicos.

- Distribución de la Tasa de Interés Activa (TA)

La TA presenta un sesgo hacia la derecha, con una alta concentración de observaciones en los valores más bajos y una cola larga hacia los valores más altos. Esto sugiere que los niveles más bajos de la TA han sido predominantes, mientras que los valores más altos han sido menos frecuentes.

- Distribución del Índice Mensual de Actividad Económica (IMAE) - Variación Interanual

La variación interanual del IMAE exhibe una distribución aproximadamente normal, centrada alrededor de cero. Este patrón indica que los cambios interanuales en la actividad económica han mostrado estabilidad relativa, con fluctuaciones que tienden a equilibrarse en el tiempo.

- Distribución del Tipo de Cambio

La distribución del tipo de cambio es asimétrica hacia la derecha, con una mayor concentración de valores en los niveles bajos y una cola que se extiende hacia los valores más altos. Esto refleja la estabilidad relativa en los niveles más bajos del tipo de cambio y menos frecuencia en las fluctuaciones hacia valores más altos.

- Distribución de las Exportaciones Netas

La distribución de las exportaciones netas tiene una forma bimodal, lo que sugiere la existencia de dos patrones bien definidos en el comportamiento de las exportaciones durante el período analizado. Esto podría estar relacionado con variaciones en los ciclos económicos o con cambios en las condiciones del comercio internacional.

- Distribución del M2 Agregado Monetario

La distribución de M2 está sesgada hacia la derecha, con una fuerte concentración en los niveles bajos y una cola larga hacia los valores más altos. Este comportamiento puede reflejar una tendencia predominante hacia niveles

más bajos del agregado monetario, con menos frecuencia de valores elevados.

- Distribución del Consumo de los Hogares

El consumo de los hogares presenta una distribución bimodal, lo que evidencia la presencia de dos patrones o regímenes distintos en el comportamiento de consumo durante el período de análisis. Esto podría estar vinculado a diferencias en el ingreso o en los patrones de gasto de los hogares.

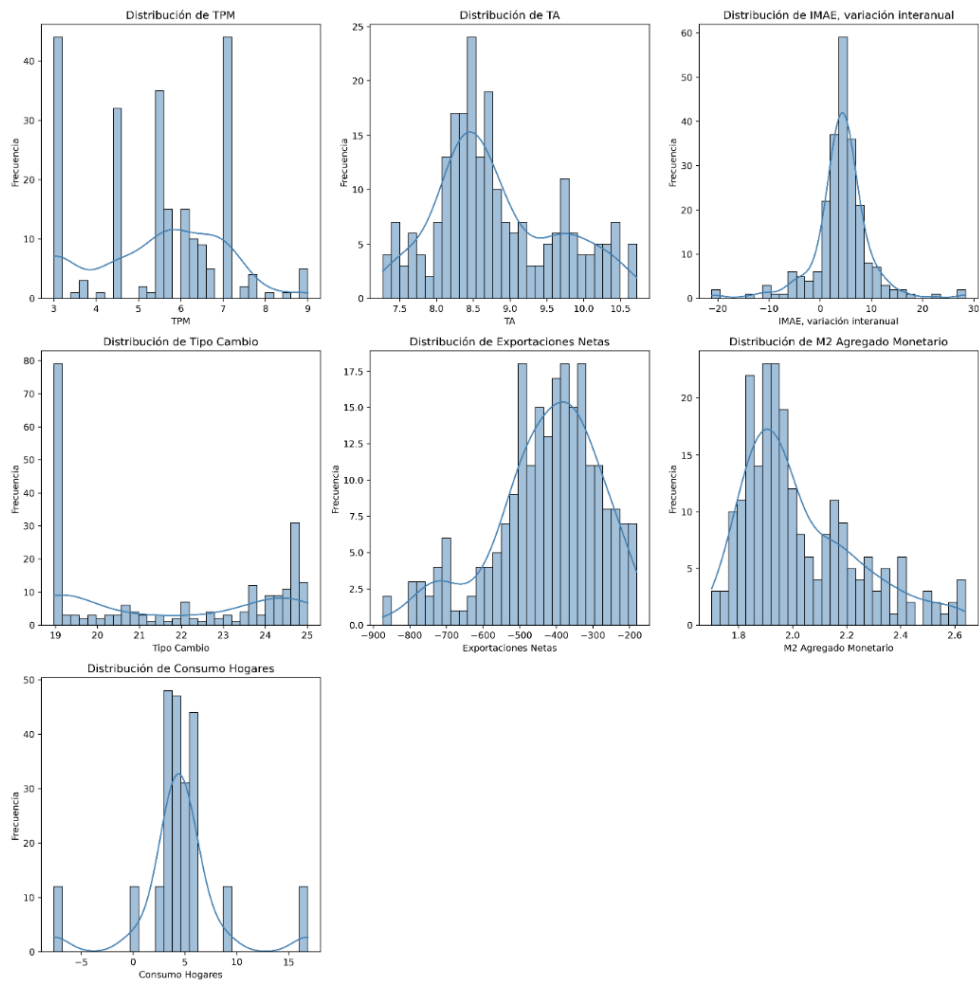


Figura 22. Distribución variables Exógenas o Independientes

Fuente: Elaboración propia

c. RELACIÓN TEMPORAL ENTRE LAS VARIABLES INDEPENDIENTES Y LA INFLACIÓN

En esta sección se analiza cómo las variables independientes o exógenas seleccionadas se relacionan con la inflación durante el período estudiado.

1. Tasa de Política Monetaria (TPM)

La Tasa de Política Monetaria (TPM) presenta una media de 5.43, una mediana de 5.50 y una desviación estándar de 1.55, lo que refleja una política monetaria relativamente estable con ligeras fluctuaciones alrededor de su promedio. En la Figura 13, se observa que la TPM sigue un comportamiento predominantemente lineal, con ajustes escalonados que responden a decisiones de política económica enfocadas en controlar la inflación y estabilizar el sistema financiero. Por otro lado, el Índice de Precios al Consumidor (IPC) muestra una variación interanual más volátil.



Figura 23. IPC y TPM

Fuente: Elaboración propia

La relación entre la Tasa de Política Monetaria (TPM) y el Índice de Precios al Consumidor (IPC) en Honduras constituye un elemento fundamental en la gestión de la estabilidad económica, dado que los ajustes en la TPM representan un mecanismo esencial para controlar las presiones inflacionarias. Este vínculo se evidencia en la influencia directa que ejerce la TPM sobre el comportamiento del IPC, particularmente en contextos de inflación elevada.

No obstante, tras la pandemia de COVID-19, el Fondo Monetario Internacional (FMI) recomendó de manera enfática al país adoptar una política monetaria más restrictiva mediante el incremento de la TPM, con el propósito de mitigar los efectos de los estímulos fiscales y de los choques en la oferta. A pesar de ello, la implementación de dicha medida se postergó hasta agosto de 2024, lo que limitó la capacidad del Banco Central de Honduras para manejar eficazmente las expectativas inflacionarias en el mediano plazo. Este retraso, sumado a un entorno económico caracterizado por la volatilidad de los precios internacionales, interrupciones en las cadenas de suministro y una recuperación económica lenta, ha dificultado la interpretación de los patrones recientes en la relación entre la TPM y el IPC, particularmente en la etapa final del período analizado.

Este contexto resalta la necesidad de decisiones monetarias más oportunas, así como de una mejor coordinación entre las políticas fiscal y monetaria, con el objetivo de salvaguardar la estabilidad macroeconómica y fortalecer la capacidad de respuesta frente a futuros desafíos económicos

2. Tasa de Interés Activa (TA)

La Tasa Activa (TA) muestra una media de 8.81, una mediana de 8.60 y una desviación estándar de 2.33, lo que indica una estabilidad moderada en sus niveles, con variaciones más controladas a lo largo del tiempo. En la Figura 14, se observa que la TA sigue una tendencia suavemente creciente desde 2020.




Figura 24. IPC y TA

Fuente: Elaboración propia

La relación entre ambas variables radica en que la TA influye en el costo del crédito, afectando la demanda agregada y, por ende, los niveles de inflación. Este vínculo resalta el

papel de la TA como un instrumento clave para mitigar los efectos inflacionarios y estabilizar la economía en períodos de alta volatilidad del IPC.

3. Distribución del Índice Mensual de Actividad Económica (IMAE) - Variación Interanual

IMAE variación interanual presenta una media de 4.14, una mediana de 4.26 y una desviación estándar de 5.62, lo que sugiere una considerable variabilidad en la actividad económica a lo largo del tiempo. EN la Figura 15, se observa que esta variación muestra fluctuaciones significativas, reflejando los cambios en el comportamiento económico.




Figura 25. IPC e IMAE VARIACION INTERANUAL

Fuente: Elaboración propia

4. Tipo de Cambio

El Tipo de Cambio (TA) muestra una media de 21.73, una mediana de 21.56 y una desviación estándar de 2.45, lo que refleja una relativa estabilidad en los niveles del tipo de cambio, con algunas fluctuaciones moderadas a lo largo del tiempo. En la Figura 16, se observa que el tipo de cambio sigue una tendencia al alza en las últimas fechas.




Figura 26. IPC y Tipo de Cambio

Fuente: Elaboración propia

5. Exportaciones Netas

Las Exportaciones Netas muestran una media de -426, una mediana de -405.67 y una desviación estándar de 144.53, lo que indica un déficit constante en las exportaciones netas a lo largo del tiempo, con algunas fluctuaciones importantes. Este comportamiento refleja que el país ha tenido consistentemente más importaciones que exportaciones durante el período observado. La desviación estándar relativamente alta sugiere que, aunque el déficit es constante, las fluctuaciones en el volumen de exportaciones e importaciones han sido notorias.




Figura 27. IPC E importaciones Netas

Fuente: Elaboración propia

6. M2 Agregado Monetario

El M2 Agregado Monetario presenta una media de 2.03, una mediana de 1.96 y una desviación estándar de 0.21, con pequeñas fluctuaciones a lo largo del tiempo. La desviación estándar baja sugiere que los cambios en el M2 son relativamente moderados.




Figura 28. IPC y M2 Agregado Monetario

Fuente: Elaboración propia

7. Consumo de los Hogares

El Consumo de los Hogares presenta una media de 4.44, una mediana de 4.27 y una desviación estándar de 4.30. La alta desviación estándar sugiere que el consumo de los hogares ha experimentado fluctuaciones notables a lo largo del tiempo.




Figura 29. IPC y Consumo Hogares

Fuente: Elaboración propia

4.2.2 MODELOS PARA PRONOSTICAR LA INFLACIÓN EN HONDURAS

4.2.2.1 REDES NEURONALES

El modelo desarrollado para este análisis se basa en redes neuronales de memoria a largo plazo (LSTM, por sus siglas en inglés, Long Short-Term Memory).

Etapas del proceso:

1. Preparación de los Datos

- Se realizaron transformaciones para asegurar la coherencia de las fechas y la correcta alineación de las variables. Este paso es crucial, ya que los modelos de redes neuronales como LSTM requieren datos sin inconsistencias.
- Normalización de los Datos

Para garantizar que el modelo pueda aprender de manera eficiente y rápida, los datos fueron normalizados utilizando el Min-Max Scaling, lo cual convierte todos los valores de las variables a un rango entre 0 y 1. Esto es esencial para mejorar la convergencia del modelo,

especialmente cuando se trabajan con redes neuronales profundas.

2. Selección de Variables Exógenas

El siguiente paso fue la selección de las variables exógenas que serían utilizadas como entradas al modelo. Estas variables son factores que no dependen directamente de la inflación, pero que pueden influir en su comportamiento.

3. Identificación de Variables Relevantes

A través de un análisis exhaustivo y con base en estudios previos sobre la dinámica económica, se seleccionaron las variables exógenas que tienen un impacto significativo en la inflación. Entre ellas se incluyen:

- Relación M2 Agregado Monetario: Este indicador refleja la cantidad de dinero en la economía y su relación con la oferta monetaria, lo que tiene un impacto directo en los niveles de inflación a través de la demanda agregada.
- Tipo de Cambio: El comportamiento del tipo de cambio puede afectar los precios de los productos importados, influenciando directamente la inflación.
- Exportaciones Netas: La diferencia entre exportaciones e importaciones puede influir en la balanza comercial y, a su vez, en la inflación, especialmente si las variaciones en los precios internacionales afectan los bienes de consumo interno.

Se cuidó de no incluir un número excesivo de variables exógenas, ya que agregar demasiadas puede perder la esencia de las redes LSTM, que están diseñadas para detectar patrones temporales a largo plazo.

4. División de los Datos

Los datos se dividieron en tres conjuntos: entrenamiento, validación y prueba. El conjunto de entrenamiento fue utilizado para ajustar los parámetros del modelo, el conjunto de validación permitió monitorear el rendimiento y evitar el sobreajuste, y el conjunto de prueba se usó para evaluar la precisión final del modelo.

5. Diseño y Configuración del Modelo LSTM

i. Estructura de la Red Neuronal

El modelo LSTM se estructuró con las siguientes capas:

- Capa LSTM: Esta capa tiene 100 unidades, lo que le permite capturar patrones temporales de largo plazo en los datos.
- Capa Dropout: Con una tasa del 20%, esta capa ayuda a regularizar el modelo y prevenir el sobreajuste.
- Capa Densa: La capa final tiene una sola neurona con activación lineal, ya que estamos prediciendo una variable continua (el IPC).

ii. Optimización y Función de Pérdida

- Optimizador: Se utilizó Adam por su eficiencia en la optimización de redes neuronales complejas.
- Función de Pérdida: Se eligió el Error Cuadrático Medio (MSE), ya que esta métrica es ampliamente utilizada en problemas de regresión.

iii. Configuración de Parámetros

- Épocas: 200 épocas, permitiendo que el modelo se ajuste adecuadamente sin caer en sobreajuste.
- Tamaño del Lote: 32, para balancear el tiempo de entrenamiento con la capacidad del modelo para aprender.
- Tasa de Aprendizaje: 0.001, un valor estándar que ayuda a la convergencia del modelo.

6. Entrenamiento del Modelo

El modelo fue entrenado utilizando los datos de entrenamiento, y el rendimiento se validó en cada época utilizando el conjunto de validación. El Early Stopping fue implementado para detener el entrenamiento si no había mejoras significativas en el conjunto de validación, evitando así el sobreajuste.

i. Iteraciones y Ajuste de Parámetros

Durante el proceso de entrenamiento, se ajustaron algunos parámetros para mejorar la precisión del modelo, especialmente la cantidad de unidades LSTM y las tasas de

aprendizaje. Los resultados se evaluaron constantemente para asegurar que no se estaba sobreajustando el modelo a los datos de entrenamiento.

7. Evaluación del Modelo

Una vez que el modelo fue entrenado y validado, se evaluó utilizando el conjunto de prueba. Las métricas de evaluación incluyeron:

- RMSE (Root Mean Squared Error): El valor obtenido fue 0.8942, lo que sugiere un rendimiento razonable del modelo en términos de error cuadrático.
- MAE (Mean Absolute Error): El MAE fue 0.6640, lo que indica que en promedio las predicciones del modelo estaban a aproximadamente 0.66 puntos del valor real.
- R² Ajustado: El valor de R² ajustado fue 0.8428, lo que indica que el modelo explica un 84.28% de la variabilidad en el IPC.

8. Ajuste Fino y Optimización Final

Después de la evaluación inicial, se procedió con un ajuste fino del modelo para mejorar su desempeño. Esto incluyó:

- Experimentar con diferentes números de capas LSTM y unidades en cada capa.
- Ajustar la tasa de aprendizaje para acelerar la convergencia sin perder precisión.
- Realizar una validación cruzada para asegurar que los resultados fueran consistentes y no dependieran demasiado de un conjunto específico de datos. Anexo 2




Figura 30. Red Neuronal IPC con Variables Exógenas

Fuente: Elaboración propia

4.2.2.2 MODELO SARIMA

Modelo SARIMA (Seasonal Autoregressive Integrated Moving Average), aplicado a la serie temporal Índice de Precios al Consumidor (IPC) variación interanual.

Etapas del proceso:

1. Preparación de los Datos

El primer paso en el proceso es la preparación de los datos, que involucra la limpieza, transformación y estructuración de la información para ser procesada por el modelo.

- Se realizaron transformaciones para asegurar la coherencia de las fechas y la correcta alineación de las variables.
- Transformación Logarítmica: Se aplica una transformación logarítmica a la variable objetivo IPC, para estabilizar la varianza y mejorar la precisión del modelo en términos de predicción.

2. División de los Datos

Una vez que los datos están listos, se dividen en dos conjuntos principales:

- Conjunto de Entrenamiento: El conjunto de datos de entrenamiento se compone de las observaciones previas a un período de 18 meses. Este conjunto es utilizado para ajustar el modelo y encontrar los parámetros más adecuados.
- Conjunto de Prueba: El conjunto de datos de prueba se toma de los últimos 18 meses y se utiliza para evaluar la capacidad predictiva del modelo ajustado. Esto permite verificar qué tan bien el modelo puede generalizar para prever datos no vistos.

3. Ajuste del Modelo SARIMA

El modelo SARIMA es un enfoque extendido del modelo ARIMA (Autoregressive Integrated Moving Average) que incorpora estacionalidad, lo cual es esencial para datos con patrones repetitivos a intervalos regulares, como los datos de IPC.

Parámetros del Modelo: SARIMA

- i. Orden No Estacional (p, d, q): (2,0,2)
 - p: El número de términos autorregresivos (AR) que capturan la relación entre la observación actual y las observaciones pasadas.
 - d: El número de diferenciaciones requeridas para hacer que la serie temporal sea estacionaria (sin tendencias significativas).
 - q: El número de términos de media móvil (MA) que modelan la relación entre la observación actual y el error de las observaciones pasadas.

- ii. Orden Estacional (P, D, Q, S): (1,1,0,12)
 - P: El número de términos autorregresivos estacionales.
 - D: El número de diferenciaciones estacionales.
 - Q: El número de términos de media móvil estacionales.
 - S: El período de estacionalidad, que en este caso es 12 debido a la naturaleza mensual de los datos (se asume que el ciclo anual es lo que define la estacionalidad). Anexo 4

El modelo SARIMA se ajusta utilizando los datos de entrenamiento, empleando estos parámetros para capturar tanto las dinámicas estacionales como las no estacionales de la serie temporal. Anexo 3

4. Generación de Predicciones

Una vez que el modelo SARIMA ha sido ajustado, se utiliza para generar predicciones sobre el conjunto de prueba.

- Pronóstico Logarítmico: El modelo realiza una predicción en la escala logarítmica, por lo que las predicciones obtenidas inicialmente están en una escala logarítmica ($\log(\text{IPC})$).
- Transformación de las Predicciones: Para que las predicciones sean interpretables en el mismo contexto que los datos originales, se aplica una transformación inversa,

utilizando la exponencial (exp), lo que permite recuperar los valores de IPC en su escala original.

5. Evaluación del Modelo

Se evaluó utilizando el conjunto de prueba., la métrica de evaluación:

1. RMSE (Root Mean Squared Error): El valor obtenido fue 0.91, lo que sugiere un rendimiento razonable del modelo en términos de error cuadrático.



Figura 31. Modelo SARIMA IPC

Fuente: Elaboración propia

4.3 OTROS RESULTADOS

El modelo desarrollado para este análisis se basa en redes neuronales de memoria a largo plazo (LSTM, por sus siglas en inglés, Long Short-Term Memory). Es importante destacar que en la estructura de este modelo no utiliza variables exógenas, limitándose exclusivamente a la serie temporal del IPC variación interanual como entrada para la predicción. Este enfoque permite evaluar la capacidad del modelo para identificar patrones y tendencias dentro de la propia serie histórica.

Etapas del proceso:

1. Preparación y Normalización de los Datos

Se parte de un conjunto de datos históricos que registra mensualmente la variación interanual de la inflación. Las fechas se transforman al formato datetime para garantizar su correcta manipulación y ordenamiento. Posteriormente, se normalizan los valores del índice mediante la técnica de escalado mínimo-máximo (MinMaxScaler), ajustando los datos al rango [0, 1]. Este paso es fundamental para garantizar un rendimiento óptimo del modelo LSTM, que es sensible a la magnitud de las entradas.

2. Creación de Conjuntos de Entrenamiento y Prueba

Con el objetivo de estructurar la serie temporal para su análisis, se define una ventana temporal de tres meses consecutivos como insumo para predecir el valor del mes siguiente. Este proceso genera un conjunto de datos estructurado en secuencias, que posteriormente se divide en un conjunto de entrenamiento, que abarca el 80% de las observaciones, y un conjunto de prueba, con el 20% restante.

3. Diseño del Modelo LSTM

El modelo es una red neuronal secuencial que consta de una capa LSTM con 50 unidades y una capa densa final que genera la predicción del valor de inflación. La configuración del modelo se optimiza mediante el algoritmo adam y utiliza el error cuadrático medio (mean squared error) como métrica de pérdida. La arquitectura fue diseñada específicamente para capturar las dinámicas temporales de la serie de inflación.

4. Entrenamiento del Modelo

El modelo se entrena a lo largo de 140 épocas, utilizando un tamaño de lote de 32 observaciones. Durante el proceso de entrenamiento, se valida el desempeño del modelo en el conjunto de prueba, lo que permite monitorear la pérdida y ajustar los hiperparámetros según sea necesario para evitar problemas de sobreajuste o subajuste.

5. Evaluación del Modelo

Las predicciones generadas por el modelo fueron comparadas con los valores reales utilizando tres métricas principales:

- RMSE (Root Mean Squared Error): 0.701, indicando un buen desempeño en términos
- El MAE fue 0.509, lo que indica que en promedio las predicciones del modelo estaban a aproximadamente 0.51 puntos del valor real.
- R^2 Ajustado: 0.903, reflejando una alta capacidad explicativa del modelo, lo que indica que el modelo explica un 90.3% de la variabilidad en el IPC.

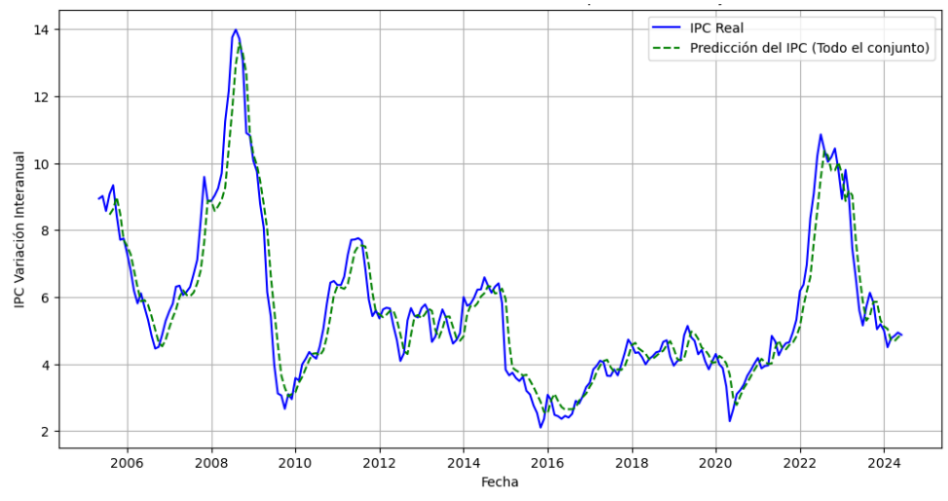


Figura 32. Comparación Valores Reales y Predichos en todo el Conjunto

Fuente: Elaboración propia

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES

1. El análisis de la variación interanual del Índice de Precios al Consumidor (IPC), utilizado como indicador principal para medir la inflación en Honduras, revela que la serie de datos no es estacionaria, lo que sugiere que los patrones y la tendencia de la inflación no permanecen constantes a lo largo del tiempo. No obstante, al aplicar la primera diferencia, se consigue estabilizar la serie, lo que facilita un análisis más preciso y robusto. Este hallazgo subraya la importancia de transformar adecuadamente los datos antes de llevar a cabo análisis de tendencias y proyecciones.
2. El estudio revela que las 16 variables económicas analizadas tienen correlaciones bajas con la variación interanual del Índice de Precios al Consumidor (IPC), lo que indica que, individualmente, no explican significativamente las fluctuaciones de la inflación. No obstante, al combinar la regresión lineal múltiple y la matriz de correlación, se identifican factores clave como la Tasa de Política Monetaria (TPM), la Tasa Activa (TA), el Índice Mensual de Actividad Económica (IMAE), el Tipo de Cambio, las Exportaciones Netas, el M2 Agregado Monetario y el Consumo de Hogares. Estos factores presentan relaciones directas e inversas con el IPC, siendo fundamentales para entender la dinámica inflacionaria. Las bajas correlaciones sugieren que pueden existir otros elementos no considerados en este análisis.
3. Los modelos utilizados para predecir la variación interanual del Índice de Precios al Consumidor (IPC) en Honduras, tanto el basado en redes neuronales con variables exógenas como el SARIMA, muestran un rendimiento adecuado. El modelo de redes neuronales destaca con un RMSE de 0.8942, un MAE de 0.6640 y un R^2 ajustado de 0.8428, indicando que explica el 84.28% de la variabilidad del IPC. En cambio, el modelo SARIMA, que se basa en valores históricos del IPC, presenta un RMSE de 0.91, con una precisión ligeramente menor. Esto resalta la ventaja de incorporar redes neuronales y variables adicionales, mejorando significativamente la capacidad de entender y prever la dinámica inflacionaria en Honduras.

4. Al comparar los modelos de redes neuronales para predecir el Índice de Precios al Consumidor (IPC) en Honduras, el modelo sin variables exógenas muestra un mejor desempeño, con un RMSE de 0.701, un MAE de 0.509 y un R^2 ajustado de 0.903, explicando el 90.3% de la variabilidad del IPC. En contraste, el modelo con variables exógenas tiene un RMSE de 0.8942, un MAE de 0.6640 y un R^2 ajustado menor. Según la literatura, este resultado puede deberse a que las expectativas inflacionarias, un factor clave en la determinación de la inflación, tienen un impacto más directo que las variables exógenas, lo que justifica la mayor precisión del modelo sin dichas variables.

5.2. RECOMENDACIONES

1. Dado que las correlaciones entre las variables analizadas y la inflación son bajas, se recomienda incluir otras variables que podrían impactar más significativamente el Índice de Precios al Consumidor (IPC). La Tasa de Política Monetaria (TPM) y el M2 Agregado Monetario muestran correlaciones positivas débiles de 0.23 y 0.29, respectivamente, mientras que el tipo de cambio y las exportaciones netas presentan correlaciones negativas de -0.33, sugiriendo interacciones complejas. Por ello, sería útil realizar análisis más especializados con enfoques econométricos avanzados para identificar con mayor precisión los factores que influyen en la inflación y mejorar la comprensión del comportamiento del IPC.
2. Para mejorar la precisión de los modelos predictivos del IPC, se sugiere incorporar un análisis detallado de las expectativas inflacionarias, ya que este factor parece influir de manera significativa en los resultados obtenidos. La literatura económica sugiere que las expectativas de inflación son un determinante clave en la evolución de los precios, lo que podría explicar las diferencias observadas en el desempeño de los modelos con y sin variables exógenas.
3. Se recomienda optimizar la arquitectura de la red neuronal LSTM ajustando el número de unidades en la capa LSTM y evaluando la posibilidad de agregar capas adicionales para mejorar la captura de patrones complejos. Asimismo, se sugiere experimentar con diferentes tasas de Dropout para encontrar el equilibrio adecuado que minimice el sobreajuste sin comprometer el aprendizaje del modelo. En cuanto

a los parámetros de entrenamiento, sería conveniente explorar otros optimizadores, como RMSprop o Nadam, y considerar funciones de pérdida robustas, como el Huber loss, para mejorar la precisión en presencia de posibles valores atípicos.

CAPÍTULO VI. APLICABILIDAD

6.1 NOMBRE DE LA PROPUESTA

Plan para la Implementación de un Modelo de Redes Neuronales Artificiales para la Estimación y Análisis de la Inflación en Honduras.

6.2 JUSTIFICACIÓN DE LA PROPUESTA

La implementación de un modelo de redes neuronales artificiales para la estimación y análisis de la inflación en Honduras representa una herramienta innovadora que contribuye a la mejora en la toma de decisiones económicas. En un entorno donde la inflación afecta significativamente la estabilidad macroeconómica, este modelo ofrece predicciones más precisas que los métodos tradicionales al identificar factores clave que influyen en su comportamiento.

El análisis predictivo del modelo permite anticipar cambios inflacionarios, lo que facilita el diseño de estrategias económicas más efectivas. Entre las aplicaciones se incluyen el ajuste de políticas públicas, la optimización de tasas de interés y la mejora en la gestión de recursos, contribuyendo al fortalecimiento de la estabilidad económica del país.

La implementación de este modelo representa una inversión estratégica con beneficios claros, tanto en términos de costo-efectividad como en la capacidad de ofrecer respuestas ágiles y fundamentadas a los desafíos inflacionarios. Asimismo, promueve el fortalecimiento técnico de las instituciones económicas clave, posicionando a Honduras como líder regional en la aplicación de inteligencia artificial en el ámbito económico.

6.3 ALCANCE DE LA PROPUESTA

El proyecto tiene como objetivo principal la implementación de un modelo de redes neuronales artificiales para la estimación y análisis de la inflación en Honduras, utilizando Python como base tecnológica. La propuesta contempla la integración del modelo en los sistemas existentes de análisis económico, permitiendo su uso en diversos escenarios.

6.3.1 OBJETIVO GENERAL DEL PROYECTO

Implementar un modelo de redes neuronales artificiales para la estimación y análisis de la inflación en Honduras, con el propósito de optimizar las decisiones económicas y

fortalecer la estabilidad macroeconómica del país.

6.3.2 OBJETIVOS ESPECÍFICOS DEL PROYECTO

1. Integración del Modelo: Integrar el modelo de redes neuronales en los sistemas existentes, asegurando su adaptabilidad y funcionamiento eficiente.
2. Análisis de Datos: Procesar, limpiar y analizar los datos obtenidos de fuentes confiables para garantizar la calidad de las entradas al modelo predictivo
3. Entrenamiento del Modelo: Utilizar técnicas avanzadas de machine learning para entrenar el modelo, maximizando su precisión y eficiencia.
4. Optimización y Validación: Validar el modelo mediante métricas como RMSE y MAE, ajustándolo para maximizar su capacidad predictiva.

6.4 FUENTES DE DATOS Y PROCESAMIENTO

6.4.1 FUENTES DE DATOS

Para este proyecto, se recurrirá a diversas fuentes confiables que ofrecen datos clave relacionados con la inflación en Honduras. Las principales fuentes de datos y sus aportes se detallan a continuación:

1. Banco Central de Honduras (BCH) proporciona indicadores macroeconómicos fundamentales:
 - El Índice de Precios al Consumidor (IPC): [Gestión de Información Económica Series Mensuales del Índice de Precios al Consumidor](#)



Figura 33. Serie IPC

Fuente: Banco Central de Honduras

- Tipo de cambio: [Gestión de Información Económica Tipo de Cambio de Compra y Venta](#)



Figura 34. Serie Tipo de Cambio

Fuente: Banco Central de Honduras

Estos datos son esenciales para capturar la dinámica económica del país y su impacto en la inflación.

2. Secretaria Ejecutiva del Consejo Monetario Centroamericano (SECMCA):
- Exportaciones netas: [params – Secmca](#)

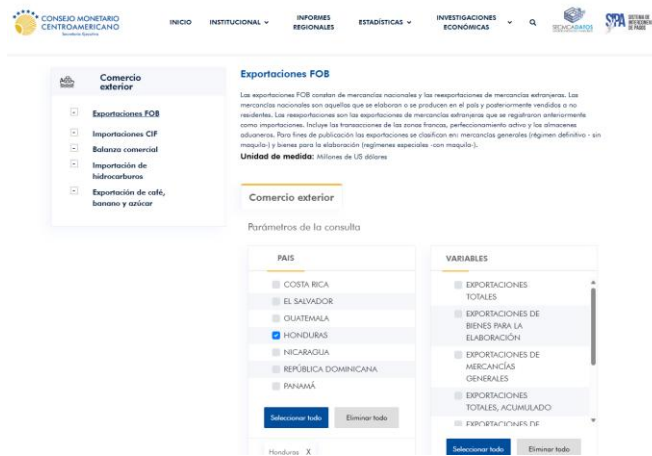


Figura 35. Serie Exportaciones Netas

Fuente: SECMCA

Las exportaciones netas afectan la balanza comercial y, por ende, la oferta y demanda de productos.

- Agregado Monetario M2: [params – Secmca](#)



Figura 36. Serie Agregado Monetario M2

Fuente: SECMCA

Los datos sobre la relación entre el agregado monetario M2 y la base monetaria amplia, relevante para entender la liquidez en la economía.

6.4.2 CONJUNTO DE DATOS

La integración de estas fuentes permite construir un conjunto de datos robusto que refleje tanto las condiciones internas como las influencias externas sobre la inflación en Honduras. A continuación, se presenta un resumen de las variables que se utilizarán:

Tabla 4. Diccionario de variables

Campo	Tipo de Dato	Descripción
Fecha	Date	Fecha de corte que fueron cargados los datos
IPC inflación Variación Interanual	Float	Niveles del índice, mide la evolución de los precios de una canasta de bienes y servicios representativa del patrón de consumo de los habitantes de cada
Tipo de Cambio	Float	Moneda nacional por unidad de US dólar
Exportaciones Netas	Float	La diferencia entre exportaciones e importaciones
M2Agregado Monetario	Float	Refleja la cantidad de dinero en la economía y su relación con la oferta monetaria
Total, Campos		5 características

Fuente: Elaboración propia

6.4.3 IMPORTACIÓN DE LIBRERÍAS

Se importan librerías para:

- Manejo de datos (numpy, pandas).
- Visualización (matplotlib).
- Escalado de datos (MinMaxScaler).
- Construcción de modelos LSTM con Keras.
- Métricas de evaluación (mean_squared_error, mean_absolute_error, r2_score).

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
```

Figura 37. Librerías

Fuente: Elaboración propia

6.4.4 LECTURA DE DATOS

Carga un archivo Excel llamado DATOS.xlsx.

```
# Lee el archivo Excel
datos = pd.read_excel('DATOS.xlsx')
```

Figura 38. Lectura de datos

Fuente: Elaboración propia

6.4.5 PROCESAMIENTO DE DATOS

1. **Gestión de Valores Faltantes:** Imputar valores nulos utilizando técnicas estadísticas como la interpolación.
2. **Estandarización:** Normalizar las variables para mejorar el rendimiento del modelo.
3. **Adecuación de Periodicidad:** Ajustar la periodicidad de los datos a una base mensual, compatible con los requerimientos del modelo.

```

# Mapeo de meses en español a números
meses = {
    'Enero': 1, 'Febrero': 2, 'Marzo': 3, 'Abril': 4, 'Mayo': 5, 'Junio': 6,
    'Julio': 7, 'Agosto': 8, 'Setiembre': 9, 'Octubre': 10, 'Noviembre': 11, 'Diciembre': 12
}
# Extraer el año y el mes del texto
datos['Año'] = datos['Fecha'].str.extract(r'(\d{4})') # Extrae el año (4 dígitos)
datos['Mes'] = datos['Fecha'].str.extract(r'([a-zA-ZñÑáéíóúÁÉÍÓÚ]+)') # Extrae el mes

# Convierte el mes al número correspondiente
datos['Mes'] = datos['Mes'].map(meses)

# Convierte a formato datetime asegurando que las columnas sean numéricas
datos['Año'] = pd.to_numeric(datos['Año'], errors='coerce') # Convierte año a número
datos['Fecha'] = pd.to_datetime({'year': datos['Año'], 'month': datos['Mes'], 'day': 1}, errors='coerce')

# Elimina columnas auxiliares específicas sin afectar las demás
datos = datos.drop(columns=['Año', 'Mes'])

# Asumiendo que 'datos' es tu DataFrame con la columna 'Fecha' y 'IPC variación interanual'
# Asegúrate de que la columna 'Fecha' esté en formato de fecha
datos['Fecha'] = pd.to_datetime(datos['Fecha'])
# Normalizamos los datos
scaler = MinMaxScaler(feature_range=(0, 1))
ipc_scaled = scaler.fit_transform(datos['IPC variación interanual'].values.reshape(-1, 1))

```

Figura 39. Procesamiento de los datos

Fuente: Elaboración propia

La función `MinMaxScaler` escala los datos del rango [0, 1] para mejorar el entrenamiento de la red neuronal.

6.5 DISEÑO E IMPLEMENTACIÓN DEL MODELO

A continuación, se presentan fragmentos del código para explicar los pasos clave:

6.5.1 DIVISION DE LOS DATOS

Se dividen los datos en conjuntos de entrenamiento 80% y prueba 20%

```

# Dividimos los datos en conjunto de entrenamiento y prueba
train_size = int(len(X) * 0.8)
X_train, X_test = X[:train_size], X[train_size:]
y_train, y_test = y[:train_size], y[train_size:]

```

Figura 40. División de los datos

Fuente: Elaboración propia

6.5.2 ESTRUCTURA DEL MODELO

- Capa LSTM con 100 unidades.
- Capa densa con 1 unidad
- Optimizador: Adam.

- Función de pérdida: Error cuadrático medio (MSE).
- 200 épocas y un tamaño de lote de 32.

```
# Definimos el modelo LSTM
model = Sequential()
model.add(LSTM(units=100, return_sequences=False, input_shape=(time_step, 1)))
model.add(Dense(units=1))
model.compile(optimizer='adam', loss='mean_squared_error')

# Entrenamos el modelo y guardamos el historial
history = model.fit(X_train, y_train, epochs=200, batch_size=32, validation_data=(X_test, y_test))
```

Figura 41. Estructura de la red neuronal artificial

Fuente: Elaboración propia

6.5.3 PREDICCIÓN Y EVALUACIÓN DEL MODELO

Las medidas de control son fundamentales para asegurar la calidad, consistencia y confiabilidad de los resultados del modelo predictivo desarrollado. A continuación, se presentan los indicadores clave de desempeño (KPIs) que permitirán evaluar la efectividad del modelo basado en redes neuronales artificiales para estimar la inflación en Honduras:

1. Índice de Desviación Media Absoluta (MAE)

Mide el promedio de las desviaciones absolutas entre los valores reales y predichos de inflación.

$$MAE = \frac{\sum |\text{Valor Real} - \text{Valor Predicho}|}{N}$$

Donde:

N= Número total de observaciones.

2. Índice de Error Cuadrático Medio (RMSE)

Indica la magnitud promedio del error en las predicciones del modelo.

$$RMSE = \sqrt{\frac{\sum (\text{Valor Real} - \text{Valor Predicho})^2}{N}}$$

Donde:

N= Número total de observaciones.

Estos indicadores proporcionan una base cuantitativa para evaluar el desempeño y el impacto del modelo predictivo, asegurando que se cumplan los objetivos del proyecto y que las estimaciones de inflación sean útiles para la toma de decisiones estratégicas.

```
# Realizamos predicciones para el conjunto de validación
y_pred = model.predict(X_test)
# Desescalamos las predicciones y los valores reales
y_pred_real = scaler.inverse_transform(y_pred)
y_test_real = scaler.inverse_transform(y_test.reshape(-1, 1))
# Métricas de error
rmse = np.sqrt(mean_squared_error(y_test_real, y_pred_real))
mae = mean_absolute_error(y_test_real, y_pred_real)
r2 = r2_score(y_test_real, y_pred_real)
```

Figura 42. predicción y evaluación del modelo

Fuente: Elaboración propia

6.5.4 PREDICCIONES FUTURAS DEL MODELO

Se generan pronósticos de inflación proyectados a 6 meses hacia adelante, proporcionando una visión anticipada del comportamiento inflacionario en el corto y mediano plazo. Esta capacidad predictiva permite evaluar posibles escenarios económicos y diseñar estrategias oportunas para mitigar riesgos y aprovechar oportunidades.

```
# Mostrar las predicciones futuras en una tabla
future_df = pd.DataFrame({
    'Fecha': future_dates,
    'Predicción del IPC': future_predictions.flatten()
})
print("\nPredicciones para los próximos meses (julio 2024 - diciembre 2024):")
print(future_df)
```

Figura 43. Predicciones Futuras

Fuente: Elaboración propia

6.6 DESPLIEGUE O AUTOMATIZACIÓN DEL SISTEMA

En esta etapa, se desarrollan scripts ejecutables que permiten la integración mensual de datos y la generación de predicciones de manera automatizada. Estos scripts garantizan la actualización continua del sistema con los datos más recientes, asegurando la relevancia y precisión de las predicciones a lo largo del tiempo. Para mantener el desempeño del modelo frente a los cambios en la dinámica económica del país, se implementará un proceso de monitoreo continuo que evalúe su funcionamiento, detecte posibles desviaciones y permita la recalibración cuando sea necesario. Este monitoreo asegura que las predicciones sigan siendo consistentes y confiables.

```
import joblib
from datetime import datetime

def generar_pronostico():
    # Cargar modelo entrenado
    model = joblib.load('modelo_lstm.pkl')

    # Cargar nuevos datos y preprocesarlos
    nuevos_datos = pd.read_csv("nuevos_datos.csv")
    datos_preprocesados = scaler.transform(nuevos_datos)

    # Generar predicción
    predicciones = model.predict(datos_preprocesados)
    print(f"Pronósticos para los próximos 6 meses: {predicciones}")

if __name__ == "__main__":
    generar_pronostico()
```

Figura 44. Ejecutable

Fuente: Elaboración propia

El sistema se empaqueta en un archivo ejecutable que incluye todas las dependencias necesarias, eliminando la complejidad de configurar entornos de desarrollo en cada equipo. Finalmente, para automatizar la ejecución del modelo, el archivo ejecutable se programa como una tarea diaria mediante gestores como el Programador de Tareas en Windows. Esto asegura que el modelo se ejecute automáticamente a una hora predeterminada sin necesidad de intervención manual. Esta estrategia optimiza la integración del modelo en los flujos de trabajo regulares y ofrece una solución escalable, adaptable y robusta para satisfacer las necesidades futuras del proyecto.

6.7 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

Este apartado presenta el cronograma de implementación para llevar a cabo el análisis de datos en la predicción de la inflación en Honduras mediante redes neuronales. Una planificación adecuada es fundamental para garantizar que todas las fases del proyecto, desde la recolección de datos hasta el desarrollo y la evaluación del modelo predictivo, se realice de manera eficiente y dentro de los plazos establecidos. El cronograma, por su parte, actuará como una guía para coordinar las actividades de los equipos involucrados y permitir el monitoreo del progreso en cada fase durante las 17 semanas de duración del proyecto.

6.7.1 PRESUPUESTO DEL PROYECTO

Dado que se aprovecharán los recursos ya disponibles en las instituciones gubernamentales, no se incurrirá en costos adicionales significativos. A continuación, se detalla cómo se optimizan los recursos:

1. Recursos Humanos: El equipo técnico está conformado por personal existente en las instituciones, que dedicará parte de su tiempo al desarrollo del proyecto. Esto elimina la necesidad de contratación externa.
2. Infraestructura y Software:
 - Herramientas de programación: Python, una herramienta de código abierto, se usará para todo el desarrollo del modelo y del ejecutable.
 - Infraestructura computacional: Se aprovecharán los servidores y equipos ya disponibles en las instituciones para el procesamiento y almacenamiento de datos.
3. Fuentes de Datos: Los datos utilizados provienen de instituciones como el Banco Central de Honduras (BCH) y SECMCA, las cuales ya cuentan con la información necesaria, eliminando costos de adquisición.

Tabla 5. Detalles del presupuesto

Recursos	Descripción	Costo Estimado
Recursos Humanos	Dedicación parcial de personal técnico existente (30 horas/semana por 17 semanas).	Cubierto dentro del salario
Infraestructura Tecnológica	Uso de servidores, computadoras y herramientas de análisis disponibles en las instituciones.	Sin costo adicional
Herramientas de Software	Uso de Python y bibliotecas de código abierto (TensorFlow, Keras, Pandas, NumPy).	Sin costo adicional
Fuentes de Datos	Datos históricos proporcionados por el BCH y SECMCA.	Sin costo adicional
Contingencias	Margen del 10% incluido para imprevistos menores en tiempo.	Sin costo adicional

Fuente: Elaboración propia

6.7.2 CRONOGRAMA DE IMPLEMENTACIÓN

La medición de tiempos en proyectos de investigación y desarrollo tecnológico es un aspecto clave dentro de la gestión de proyectos, ya que permite planificar, ejecutar y controlar el progreso de manera eficiente. Para este propósito, se recurre a herramientas y metodologías fundamentadas en teorías de administración del tiempo y análisis de productividad.

El método utilizado para medir y estimar tiempos se basa en los principios de la Teoría de la Gestión del Tiempo de Taylor y Gantt, que se centra en los siguientes puntos clave:

1. División del Trabajo:

Cada tarea se descompone en actividades más pequeñas y manejables, lo que facilita su planificación y medición. Esto asegura que todas las actividades sean visibles, medibles y asignables.

2. Asignación de Recursos:

La duración de cada actividad está directamente relacionada con los recursos asignados (humanos, tecnológicos y de tiempo). Para este proyecto, los recursos humanos están representados por horas semanales de trabajo dedicadas exclusivamente al desarrollo del modelo.

3. Tiempos Estándar:

Cada actividad tiene una estimación estándar basada en experiencias previas, simulaciones y las capacidades esperadas del equipo de trabajo. Este estándar permite realizar ajustes en caso de desvíos.

La implementación del modelo de redes neuronales artificiales para la estimación y predicción de la inflación en Honduras se desarrollará en 17 semanas , distribuidos en diferentes fases según el enfoque metodológico. Cada fase incluirá actividades específicas y se medirá con indicadores claros de avance.

6.7.2.1.METODOLOGÍA DE ESTIMACIÓN DEL TIEMPO

El tiempo requerido para cada fase fue calculado utilizando la fórmula.:

$$T_f = \frac{\text{Esfuerzo Total Estimado (ET)}}{\text{Productividad (P)}}$$

Donde:

- T_f : Tiempo estimado por fase (en semanas).
- ET: Esfuerzo total estimado (en horas).
- P: Productividad, medida en horas efectivas trabajadas por semana.

La Duración Total del Proyecto se calcula sumando las duraciones estimadas de todas las fases planificadas, considerando los tiempos asignados a cada etapa del desarrollo del modelo

$$T_p = \sum_{i=1}^n (T_{fi})$$

Donde T_p es el tiempo total del proyecto y T_{fi} es el tiempo estimado para la actividad i.

En este proyecto, se considera con una dedicación de 30 horas efectivas por semana.

6.7.2.2.CRONOGRAMA POR FASES

- **Fase 1 Análisis de Datos y Diseño del Modelo**

Actividades principales:

1. Recolección de datos: Obtener y consolidar las bases de datos relevantes, verificando su calidad y completitud.
2. Preprocesamiento de datos: Imputación de valores faltantes, detección de atípicos y normalización de las variables.
3. Diseño del modelo: Definir la arquitectura inicial del modelo basado en redes neuronales artificiales (LSTM).

$$TF1 = \frac{180 \text{ horas}}{30 \text{ horas / semana}} = 6 \text{ semanas}$$

- **Fase 2 Desarrollo del Modelo**

Actividades principales:

1. Entrenamiento del modelo: Implementar y entrenar la red neuronal utilizando bibliotecas como TensorFlow y Keras.
2. Optimización del modelo: Ajustar hiperparámetros como la tasa de aprendizaje, el número de capas ocultas y el tamaño de lote.
3. Validación inicial: Probar el modelo con datos históricos para evaluar su desempeño.

$$TF2 = \frac{270 \text{ horas}}{30 \text{ horas / semana}} = 9 \text{ semanas}$$

- **Fase 3 Automatización y Validación Final**

Actividades principales:

1. Automatización: Crear un ejecutable en Python que integre el modelo y procese datos de manera automática.
2. Validación final: Comparar los pronósticos generados por el modelo con valores reales y ajustar posibles desviaciones.
3. Documentación: Redactar manuales técnicos para el uso del ejecutable y el

mantenimiento del modelo.

$$T_{F3} = \frac{60 \text{ horas}}{30 \text{ horas / semana}} = 2 \text{ semanas}$$

Tabla 6. Resumen de las fases

Fase	Duración (semanas)	Duración (meses)	EsfuerzoTotal (horas)
Análisis de Datos y Diseño del Modelo	6	1.5	180
Desarrollo del Modelo	9	2.25	270
Automatización y Validación Final	2	0.5	60
Total	17	7	510

Fuente: Elaboración propia

Tabla 7. Cronograma de implementación

Semana	Actividad
Mes 1 - 2: Fase 1 (Análisis de Datos y Diseño del Modelo)	
1-2	Recolección de datos y revisión de calidad
3-4	Preprocesamiento de datos
5-6	Diseño preliminar del modelo LSTM
Mes 3-4: Fase 2 (Desarrollo del Modelo)	
7-8	Entrenamiento inicial del modelo
9-11	Optimización de hiperparámetros
12-15	Validación inicial con datos históricos
Mes 4: Fase 3 (Automatización y Validación Final)	
16-17	Desarrollo del ejecutable en Python y Validación final del modelo

Fuente: Elaboración propia

6.8 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

Tabla 8. Matriz de Concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías/ Metodologías de sustento	Variables	Población	Técnicas	Conclusiones	Nombre de la propuesta	Objetivos propuesta
Análisis y Estimación de la Inflación en Honduras Mediante Redes Neuronales	Desarrollar la propuesta de un modelo basado en redes neuronales para predecir la inflación mensual en Honduras, analizando los factores macroeconómicos y microeconómicos que influyen en este fenómeno, con el fin de proporcionar	Identificar y analizar los factores clave que impulsan la inflación en Honduras, considerando tanto variables macroeconómicas como microeconómicas, para comprender su impacto en el fenómeno inflacionario.	Teoría Económica	Sector Monetario/ Financiero	La población de estudio está compuesta por series de datos mensuales que abarca desde el año 1990 hasta junio de 2024. Estos datos incluyen variables macroeconómicas y microeconómicas relevantes para el análisis de la inflación en Honduras, las cuales son fundamentales para entender los	Minería de Datos	Se identifican factores clave que influyen en el comportamiento del IPC. Entre ellos destacan la Tasa de Política Monetaria (TPM), la Tasa Activa (TA), el Índice Mensual de Actividad Económica (IMAE), el Tipo de Cambio, las Exportaciones Netas, el M2 Agregado Monetario y el Consumo de Hogares, todos los cuales presentan relaciones tanto directas	Plan para la Implementación de un Modelo de Redes Neuronales Artificiales para la Estimación y Análisis de la Inflación en Honduras	Integración del Modelo
		Evaluar la precisión de los modelos de redes neuronales en la predicción de la inflación mensual en Honduras, mediante la comparación	Teoría de Política Monetaria	Sector Externo/ Comercial					Análisis de Datos

Continuación de la Tabla 8. Matriz de Concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías/ Metodologías de sustento	Variables	Población	Técnicas	Conclusiones	Nombre de la propuesta	Objetivos propuesta
	pronósticos más precisos y útiles para la toma de decisiones económicas.	de sus resultados con los de modelos tradicionales de pronósticos			factores que inciden en el comportamiento de los precios en el país.		como inversas con el IPC.		
		Optimizar las redes neuronales para maximizar su rendimiento en la predicción de la inflación mensual, identificando las configuraciones y técnicas que mejoren su capacidad de captar la interacción no lineal de las variables involucradas	Teoría de Analítica Predictiva	Actividad Económica		Modelos Predictivos	Los modelos empleados para la predicción de la variación interanual del Índice de Precios al Consumidor (IPC) en Honduras, tanto el modelo con redes neuronales y variables exógenas como el modelo SARIMA, han demostrado un rendimiento razonablemente adecuado. El modelo de redes		

Continuación de la Tabla 8. Matriz de Concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías/ Metodologías de sustento	Variables	Población	Técnicas	Conclusiones	Nombre de la propuesta	Objetivos propuesta
		Elaborar una propuesta para la implementación de un algoritmo de redes neuronales que permita la predicción de la inflación en Honduras, evaluando su viabilidad y el impacto potencial en la precisión de los pronósticos					neuronales, al incorporar variables exógenas, muestra un desempeño superior, con un valor de RMSE de 0.8942		Optimización y validación

Continuación de la Tabla 8. Matriz de Concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías/ Metodologías de sustento	Variables	Población	Técnicas	Conclusiones	Nombre de la propuesta	Objetivos propuesta
		económicos del país							

Fuente: Elaboración propia

REFERENCIAS BIBLIOGRÁFICAS

Referencias

- Alija, A. (2020). Tecnologías emergentes y datos abiertos: Analítica Predictiva. https://datos.gob.es/sites/default/files/doc/file/informe-analitica-predictiva-vr-es_1.pdf
- Álvarez, F. F. (2016). Inflación y Crecimiento Económico: umbral para Honduras: Banco Central de Honduras. https://www.bch.hn/estadisticos/DIE/Investigaciones%20economicas/inflacion_y_crecimiento_economico.pdf
- Argandoña, A. (1990). El pensamiento económico de Milton Friedman. <https://www.iese.edu/media/research/pdfs/DI-0193.pdf>
- Banco Central de Honduras (2004). Ley del Banco Central de Honduras. https://www.bch.hn/administrativas/JUR/Marco%20Legal%20OM%202/ley_bch.pdf
- Banco Central de Honduras (2023). Informe de Estabilidad Financiero. <https://www.bch.hn/estadisticos/EF/LIBINFORME/IEF%20diciembre%202023.pdf>
- Banco Central de Honduras (2024). Índice de Precios al Consumidor. <https://www.bch.hn/estadisticos/GIE/LIBIPC/%C3%8Dndice%20de%20Precios%20al%20Consumidor%20Octubre%202024.pdf>
- Banco Central de la República Argentina (2024). Determinantes de la inflación en Argentina, 2004-2022. https://ri.conicet.gov.ar/bitstream/handle/11336/240276/CONICET_Digital_Nro.120490-fc8b-4a65-a9cb-7e510a543796_B.pdf?sequence=2&isAllowed=y
- Banco Central del Ecuador. (2012). *Sector Externo*. <https://www.bce.fin.ec/component/k2/sector-externo>
- Banco Central del Ecuador. (2015). *Sector Monetario Financiero*. <https://www.bce.fin.ec/component/k2/sector-monetario-financiero>
- Banco de España (2024). Proyecciones macroeconómicas e informe trimestral de la economía española. Septiembre de 2024. *Boletín Económico*. Publicación en línea avanzada. <https://doi.org/10.53479/37657>
- Barrera Bolívar, A. C. (2020). Diseño e implementación de un modelo analítico predictivo para el apoyo en la toma de decisiones enfocado en las empresas de telecomunicaciones. <https://repository.usta.edu.co/bitstream/handle/11634/30071/2020camilobarrera.pdf?seq>
- Baybuza, I. (2018). Inflation Forecasting Using Machine Learning Methods. *Russian Journal of Money and Finance*, 42–59. <https://doi.org/10.31477/rjmf.201804.42>
- BlackBeast. (2024). *Analítica Predictiva*. <https://blackbeast.pro/diccionario/analitica-predictiva/>
- Bobadilla, J. (2020). Machine learning y deep learning. Usando python. https://api.pageplace.de/preview/DT0400.9789587921465_A41974869/preview-

- 9789587921465_A41974869.pdf
- Bugueiro, A. B. (2024). Modelos de inflación: predicción y análisis de impactos. http://eamo.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_2259.pdf
- Calle García, A. J., Aviles Barcia, E. M., Baque Reina, E. A. y Muñiz Rodriguez, F. S. (2024). El Papel de la Analítica Predictiva en la Anticipación de Cambios en el Entorno Empresarial. <http://revistas.uap.edu.pe/ojs/index.php/CYD/index>
- Cardona Echeverri, D., Gaitán Riaño, S. y Velásquez Ceballos, H. (2016). Variables macroeconómicas y microeconómicas que influyen en la estimación del costo de capital: un estudio de caso. *Revista Facultad De Ciencias Económicas*, 25(1). <https://doi.org/10.18359/rfce.2657>
- Centeno Franco, A. (2019). Deep Learning. <https://idus.us.es/bitstream/handle/11441/90004/Centeno%20Franco%20Alba%20FG.pdf>
- Chilón Ayay, A. L. (2023). *Redes neuronales recurrentes y modelos arima para el pronóstico de la inflación en el Perú*. Universidad Nacional de Trujillo. <https://dspace.unitru.edu.pe/items/1bc6fc97-85fb-4fdc-ac92-936ac45333cd>
- Comisión Nacional de Bancos y seguros (2023). Informe Estabilidad Financiera. [https://publicaciones.cnbs.gob.hn/Home/Viewer/Publicaciones%20Estad%20C3%ADstic%20y%20Financieras%20Estudios%20e%20Informes%20Informe%20de%20Estabilidad%20Financiera%20FA%20C3%B1o%202023%20diciembre/Informe%20Estabilidad%20Financiera%20\(cifras%20cierre%202023\).pdf](https://publicaciones.cnbs.gob.hn/Home/Viewer/Publicaciones%20Estad%20C3%ADstic%20y%20Financieras%20Estudios%20e%20Informes%20Informe%20de%20Estabilidad%20Financiera%20FA%20C3%B1o%202023%20diciembre/Informe%20Estabilidad%20Financiera%20(cifras%20cierre%202023).pdf)
- Cruz Martínez, E. d. J., Ávila Romero, R. y Chiatchoua, C. (2024). Análisis de la inflación y el crecimiento económico un enfoque de Machine Learning. México 1990-2021, *Universidad y Sociedad* 16(3), 174-188.
- Cruz Torres, C. A. (2023). Las capas en la persistencia de la inflación en Honduras: Banco Central de Honduras.
- La Editora (2013). Constitución de la República de Honduras. *La Revista De Derecho*, 30, 132–220. <https://doi.org/10.5377/lrd.v30i0.1237>
- Enciclopedia Financiera. (2023). *Teoría Económica*. <http://www.encyclopediainanciera.com/teoriaeconomica.htm>
- FMI. (2023). *Resilient Global Economy Still Limping Along, With Growing Divergences*. International Monetary Fund; Gourinchas, Pierre-Olivier. <https://www.imf.org/en/Blogs/Articles/2023/10/10/resilient-global-economy-still-limping-along-with-growing-divergences>
- FocusEconomics. (2024). *La inflación cae en agosto a su nivel más bajo desde febrero de 2021*. <https://www.focus-economics.com/es/countries/estados-unidos/news/inflacion/united-states-consumer-prices-11-09-2024-la-inflacion-cae-en-agosto-a-su-nivel-mas-bajo-desde-febrero-de-2021/>
- Fondo Monetario Internacional. (2024). *A medida que la inflación retrocede, la economía mundial necesita un triple giro en las políticas*. <https://www.imf.org/es/Blogs/Articles/2024/10/22/as-inflation-recedes-global-economy-needs-policy-triple-pivot>
- Friedman, B. M. (1984). The Value of Intermediate Targets in Implementing Monetary Policy. *Price Stability and Public Policy*. <https://www.kansascityfed.org/Jackson%20Hole/documents/3903/1984-S84FRIED.pdf>
- La Gaceta (2006). Ley para la defensa y promoción de la competencia.

- <https://www.tsc.gob.hn/web/leyes/Ley%20para%20la%20Defensa%20y%20Promoci%C3%B3n%20de%20la%20Competencia.pdf>
- La Gaceta (2008). Ley de Protección al Consumidor.
<https://www.tsc.gob.hn/web/leyes/Ley%20de%20Protecci%C3%B3n%20al%20Consumidor.pdf>
- Guazzelli, A. (2012). *Analítica Predictiva*.
<https://es.scribd.com/document/435093481/AnaliticaPredictiva>
- Gutiérrez Andrade, O. y Zurita Moreno, A. (2006). Sobre la inflación. *PERSPECTIVAS*, 9(3), 81–115. <https://www.redalyc.org/pdf/4259/425942413004.pdf>
- Heath, J. (2012). Lo que indican los indicadores: Cómo utilizar la información estadística para entender la realidad económica de México.
<https://archivos.juridicas.unam.mx/www/bjv/libros/11/5238/12.pdf>
- Herbrich, R., Keilbach, M., Graepel, T., Bollmann-Sdorra, P. y Obermayer, K. (1999). Neural Networks in Economics. En T. Brenner (Ed.), *Advances in Computational Economics: v. 11. Computational techniques for modelling learning in economics* (Vol. 11, pp. 169–196). Kluwer Academic Publishers. https://doi.org/10.1007/978-1-4615-5029-7_7
- Hernández Sampieri, R. (2010). *Metodología de la investigación* (5a ed.). McGraw-Hill.
- Instituto Nacional de Estadística (2024). Indicador adelantado del Índice de Precios de Consumo (IPC). <https://www.ine.es/dyngs/Prensa/es/adIPC1224.htm>
- Instituto Nacional de Estadística e Informática (2018). Perú: Estructura Empresarial, 2018. https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1703/anexo02.pdf
- Jaramillo, C. F. y O'Brien, R. T. (2022). La inflación, una amenaza creciente, *10*.
<https://centroculturalisol.com/La%20inflaci%C3%B3n,%20una%20amenaza%20creciente.pdf>
- Legal Cañisá, S. J. R. (2024). Inflación en Paraguay (1989 – 2021): Determinantes multicausales de largo plazo. *Latam: revista latinoamericana de Ciencias Sociales y Humanidades*, 5(2), 12. <https://dialnet.unirioja.es/servlet/articulo?codigo=9541031>
- León León, J. y de la Rosa Mendoza, J. R. (2005). Política monetaria, cortos y estabilidad macroeconómica. <https://www.redalyc.org/pdf/413/41304313.pdf>
- Life Pacific University. (2023). *Estrategias de Investigación: Tipo De Fuentes*.
<https://lifepacific.libguides.com/c.php?g=924149&p=6696820>
- Loaiza Zapata, J. F. (2022). Pronóstico de la inflación colombiana: una aproximación desde los modelos machine learning.
<https://repository.eafit.edu.co/server/api/core/bitstreams/f36cceb0-c8fd-44cb-870e-167188cc214b/content>
- Lugo Cabrera, C. M. y López Herrera, J. (2018). *Analítica de Datos con aplicación en un caso práctico, mediante el uso de una herramienta libre*.
<https://repositorio.utp.edu.co/server/api/core/bitstreams/46ecf856-3fb8-4a85-8ebd-510eddb48a7a/content>
- Luna Pérez, M. A. y Vázquez Álvarez, G. (2019). *Metodología de mantenimiento predictivo 4.0*. <https://www.iiisci.org/journal/pdv/risci/pdfs/ca639li19.pdf>
- Mancera, C. y Agustín (2003). Redalyc.Samuelson y la enseñanza de la teoría económica, *18(38)*, 297–324. <https://www.redalyc.org/pdf/413/41303814.pdf>
- Mateos, C. y Gaytán, A. (1998). Medidas Alternativas de inflación. *Banco De México*.
https://web.archive.org/web/20210416070339id_/https://www.banxico.org.mx/publi

- caciones-y-prensa/documentos-de-investigacion-del-banco-de-mexico/%7B5B13C543-1D84-C1C6-FCBD-AB42FDC56E99%7D.pdf
- Montero Granados, R. (2016). Modelos de regresión lineal múltiple. https://www.ugr.es/~montero/matematicas/regresion_lineal.pdf
- Mora, A. (2018). Utilización de Redes Neuronales Artificiales (RNA) como alternativa para el pronóstico del Índice de Precios al Consumidor (IPC) y contraste de resultados con modelos estadísticos tradicionales (ARIMA y VAR) para el Ecuador periodo 2000-2017. <https://dspace.ucuenca.edu.ec/bitstream/123456789/31730/1/Trabajo-de-Titulaci%c3%b3n.pdf>
- Novales, A. (2017). Modelos vectoriales autoregresivos. <https://www.ucm.es/data/cont/media/www/pag-41459/VAR.pdf>
- Olmedo, Elena, Valderas, Manuel, J., Mateos, Ruth, Gimeno y Ricardo (2004). Utilización de redes neuronales en la caracterización, modelización y predicción de series temporales económicas en un entorno complejo. *Revista Iberoamericana De Inteligencia Artificial*, 8(23). Disponible en: <http://www.redalyc.org/articulo.oa?id=92502302>
- Orellana R, W., Lora R, O., Mendoza, R. y Boyán, R. (2000). La Política Monetaria en Bolivia y sus Mecanismos de Transmisión. https://www.bcb.gob.bo/webdocs/publicacionesbcb/revista_analisis/ra_vol032000/articulo_3_v3_1_2000.pdf
- Purnawansyah, Haviluddin, Setyadi, H. J., Wong, K. y Alfred, R. (2019). An Inflation Rate Prediction Based on Backpropagation Neural Network Algorithm. *International Journal of Artificial Intelligence Research*, 3(2). <http://ijair.id/index.php/ijair/article/view/112/pdf>
- Quiñonez, J., Serrano Fernández, J. y Solano Hidalgo, V. (2024). Expectativas de inflación en Centroamérica: Análisis de los casos de Costa Rica, Guatemala, Honduras y República Dominicana: Consejo Monetario Centroamericano. <https://www.secmca.org/wp-content/uploads/2024/08/Analisis-de-las-expectativas-de-inflacion-en-CR-GT-HN-y-RD.pdf>
- Reyes, N. R. y Gómez, J. E. (2000). Política monetaria, inflación y crecimiento económico. *Cuadernos de economía (Santafé de Bogotá)*, 19(32), 139–153. <https://dialnet.unirioja.es/servlet/articulo?codigo=4934998>
- Riquelme, J. C., Ruiz, R. y Gilbert, K. (2006). Minería de Datos: Conceptos y Tendencias. *Iberoamericana De Inteligencia Artificial*, 10(29), 11–18. <https://www.redalyc.org/pdf/925/92502902.pdf>
- Rivas Asanza, W. y Mazón Olivo, B. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones*. https://www.researchgate.net/profile/bertha-mazon-olivo/publication/327703478_capitulo_1_generalidades_de_las_redes_neuronales_artificiales/links/5b9fe3c0299bf13e6038a1d8/capitulo-1-generalidades-de-las-redes-neuronales-artificiales.pdf
- Rosenthal, G. (2010). La crisis financiera y económica de 2008 y su repercusión en el pensamiento económico. *CEPAL*. <https://repositorio.cepal.org/server/api/core/bitstreams/6e27eb27-010e-431c-ae9c-7f3edc3f28d9/content>
- Saladrigas, M. M. (2022). La inteligencia artificial: su aplicación en las empresas: Ciudad de Buenos Aires, Argentina, 2020-2022. *Doctoral Dissertation, Universidad De*

- Belgrano-Facultad De Ciencias Económicas-Licenciatura En Comercio Exterior.*
<https://repositorio.ub.edu.ar/bitstream/handle/123456789/10016/TESINA-SALADRIGAS%20Mar%c3%ada%20Monserrat.pdf?sequence=1&isAllowed=y>
- Schwartz, M. J. y Galván, S. (1999). *Teoría Económica y Credibilidad en la Política Monetaria.* <https://www.banxico.org.mx/publicaciones-y-prensa/documentos-de-investigacion-del-banco-de-mexico/%7BEF1F0A6C-7E35-B7FB-D8E0-8ADAA4C9CF9F%7D.pdf>
- Schwartz, M. J. y Sybel, G. (1999). *Teoría Económica y Credibilidad en la Política Monetaria.*
https://web.archive.org/web/20210227174004id_/https://www.banxico.org.mx/publicaciones-y-prensa/documentos-de-investigacion-del-banco-de-mexico/%7BEF1F0A6C-7E35-B7FB-D8E0-8ADAA4C9CF9F%7D.pdf
- SECMCA (2019). *ACUERDO MONETARIO CENTROAMERICANO.*
<https://www.secmca.org/wp-content/uploads/2019/02/Acuerdo-Monetario-Centroamericano.pdf>
- SECMCA. (2024). *Reporte Mensual de inflación regional noviembre 2024.*
- SEFIN. (2000). *Memora Anual 2000 secretaria de Finanzas de Honduras.*
- SEFIN (2018). *Código Tributario y sus Reformas.* https://www.sefin.gob.hn/wp-content/uploads/2018/06/Texto_Consolidado_Codigo_Tributario_25JUNIO2018_Y_ANEXOS.pdf
- Statista. (2024a). *Ranking de inflación en América Latina y el Caribe por tasa de inflación 2023 y 2024.* <https://es.statista.com/estadisticas/1280168/paises-por-tasa-de-inflacion-en-america-latina-y-el-caribe/>
- Statista. (2024b). *Tasa de inflación en Argentina 2024.*
<https://es.statista.com/estadisticas/1189933/tasa-de-inflacion-argentina/>
- Statista. (2024c). *Tasa de inflación mundial 2010-2029.*
<https://es.statista.com/estadisticas/495587/tasa-de-inflacion-global-respecto-al-ano-anterior/>
- Tablada, C. J. y Torres, G. A. (2009). *Redes Neuronales Artificiales. Revista de Educación Matemática, 24(3).* <https://doi.org/10.33044/revem.10280>
- Trading Economics. (2024a). *Estados Unidos - Tasa de inflación | 1914-2024 Datos | 2025-2027 Expectativa.* <https://es.tradingeconomics.com/united-states/inflation-cpi>
- Trading Economics. (2024b). *La tasa de inflación anual de Paraguay.*
<https://es.tradingeconomics.com/paraguay/inflation-cpi>
- UNAH (2022). *Inflación: Panorama y Desafíos para la Economía Hondureña.*
<https://dircom.unah.edu.hn/dmsdocument/13360-boletin-unah-030-julio-2022-pdf>
- Uquillas, A. y González, C. (2017). *Determinantes macro y microeconómicos para pruebas de tensión de riesgo de crédito: un estudio comparativo entre Ecuador y Colombia basado en la tasa de morosidad. Ensayos Sobre Política Económica, 35(84), 245–259.* <https://doi.org/10.1016/j.espe.2017.11.002>
- Villavicencio, J. (2010). *Introducción a series de tiempo.*

ANEXOS

Anexo 1

OLS Regression Results

```

=====
Dep. Variable:   IPC variaci3n interanual   R-squared:           0.760
Model:          OLS                       Adj. R-squared:      0.744
Method:         Least Squares             F-statistic:         48.53
Date:           Sat, 23 Nov 2024          Prob (F-statistic):  1.43e-58
Time:           15:50:56                  Log-Likelihood:     -358.60
No. Observations: 230                    AIC:                 747.2
Df Residuals:   215                      BIC:                 798.8
Df Model:       14
Covariance Type: nonrobust
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	-9.6324	4.724	-2.039	0.043	-18.943	-0.322
TPM	1.4373	0.120	12.024	0.000	1.202	1.673
TA	2.2993	0.368	6.253	0.000	1.575	3.024
TP	-4.4076	0.501	-8.805	0.000	-5.394	-3.421
IMAE	-0.0305	0.013	-2.390	0.018	-0.056	-0.005
IMAE, variaci3n interanual	-0.0939	0.031	-2.998	0.003	-0.156	-0.032
PIB trimestral	9.212e-05	7.04e-05	1.309	0.192	-4.66e-05	0.000
PIB trimestral variaci3n interanual	-0.0197	0.037	-0.533	0.594	-0.092	0.053
Tipo Cambio	-0.5910	0.174	-3.405	0.001	-0.933	-0.249
Remesas	0.0023	0.003	0.893	0.373	-0.003	0.007
Credito Total	-9.766e-06	2.95e-06	-3.314	0.001	-1.56e-05	-3.96e-06
Reservas Internacionales	0.0013	0.000	7.797	0.000	0.001	0.002
Exportaciones	0.0017	0.001	2.900	0.004	0.001	0.003
Importaciones	0.0043	0.001	6.861	0.000	0.003	0.006
Exportaciones Netas	-0.0026	0.001	-3.622	0.000	-0.004	-0.001
M2 Agregado Monetario	1.5424	0.878	1.756	0.081	-0.189	3.274

```

=====
Omnibus:        2.915   Durbin-Watson:      0.621
Prob(Omnibus):  0.233   Jarque-Bera (JB):   2.655
Skew:           0.170   Prob(JB):           0.265
Kurtosis:       3.402   Cond. No.           3.65e+18
=====

```

Notes:

[1] Standard Errors assume that the covariance matrix of the errors is correctly specified.

[2] The smallest eigenvalue is 2.61e-24. This might indicate that there are strong multicollinearity problems or that the design matrix is singular.

Anexo 2

```
Jupyter Untitled1 Last Checkpoint: last month
File Edit View Run Kernel Settings Help Trust
Python 3 (ipykernel)

Red Neuronal

[ ]: import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# Lee el archivo Excel
datos = pd.read_excel("DATOS.xlsx")

# Mapeo de meses en español a números
meses = {
    'Enero': 1, 'Febrero': 2, 'Marzo': 3, 'Abril': 4, 'Mayo': 5, 'Junio': 6,
    'Julio': 7, 'Agosto': 8, 'Septiembre': 9, 'Octubre': 10, 'Noviembre': 11, 'Diciembre': 12
}

# Extraer el año y el mes del texto
datos['Año'] = datos['Fecha'].str.extract(r'(\d{4})') # Extrae el año (4 dígitos)
datos['Mes'] = datos['Fecha'].str.extract(r'([a-zA-Z]{3})') # Extrae el mes

# Convierte el mes al número correspondiente
datos['Mes'] = datos['Mes'].map(meses)

# Convierte a formato datetime asegurando que las columnas sean numéricas
datos['Año'] = pd.to_numeric(datos['Año'], errors='coerce') # Convierte año a número
datos['Fecha'] = pd.to_datetime({'year': datos['Año'], 'month': datos['Mes'], 'day': 1}, errors='coerce')

# Elimina columnas auxiliares específicas sin afectar las demás
datos = datos.drop(columns=['Año', 'Mes'])

# Asegurando que 'datos' es tu DataFrame con la columna 'Fecha' y 'IPC variación Interanual'
# Asegúrate de que la columna 'Fecha' esté en formato de fecha
datos['Fecha'] = pd.to_datetime(datos['Fecha'])
# Normalizamos los datos
scaler = MinMaxScaler(feature_range=(0, 1))
ipc_scaled = scaler.fit_transform(datos['IPC variación Interanual'].values.reshape(-1, 1))

# Preparamos los datos para el modelo LSTM
def create_dataset(data, time_step=3):
    X, y = [], []
    for i in range(len(data) - time_step):
        X.append(data[i:(i + time_step), 0])
        y.append(data[i + time_step, 0])
    return np.array(X), np.array(y)
# Creamos las secuencias de entrenamiento
time_step = 3 # Usamos los últimos 3 meses para predecir el siguiente
X, y = create_dataset(ipc_scaled, time_step)

# Reshape de los datos para LSTM
X = X.reshape(X.shape[0], X.shape[1], 1)

# Dividimos los datos en conjunto de entrenamiento y prueba
train_size = int(len(X) * 0.8)
X_train, X_test = X[:train_size], X[train_size:]
y_train, y_test = y[:train_size], y[train_size:]

# Definimos el modelo LSTM
model = Sequential()
model.add(LSTM(units=100, return_sequences=False, input_shape=(time_step, 1)))
model.add(Dense(units=1))
model.compile(optimizer='adam', loss='mean_squared_error')

# Entrenamos el modelo y guardamos el historial
history = model.fit(X_train, y_train, epochs=200, batch_size=32, validation_data=(X_test, y_test))

# Realizamos predicciones para el conjunto de validación
y_pred = model.predict(X_test)
# Desescalamos las predicciones y los valores reales
y_pred_real = scaler.inverse_transform(y_pred)
y_test_real = scaler.inverse_transform(y_test.reshape(-1, 1))

# Métricas de error
rmse = np.sqrt(mean_squared_error(y_test_real, y_pred_real))
mae = mean_absolute_error(y_test_real, y_pred_real)
r2 = r2_score(y_test_real, y_pred_real)

# Mostramos las predicciones futuras en una tabla
future_df = pd.DataFrame({
    'Fecha': future_dates,
    'Predicción del IPC': future_predictions.flatten()
})
print("\nPredicciones para los próximos meses (Julio 2024 - diciembre 2024):")
print(future_df)
```

Anexo 3

SARIMA

```
import numpy as np
import pandas as pd
import statsmodels.api as sm
import plotly.graph_objects as go
from statsmodels.tsa.statespace.sarimax import SARIMAX

# Leer el archivo de datos
datos = pd.read_excel('DATOS.xlsx')

# Mapeo de meses en español a números
meses = {
    'Enero': 1, 'Febrero': 2, 'Marzo': 3, 'Abril': 4, 'Mayo': 5, 'Junio': 6,
    'Julio': 7, 'Agosto': 8, 'Setiembre': 9, 'Octubre': 10, 'Noviembre': 11, 'Diciembre': 12
}

# Extraer el año y el mes del texto
datos['Año'] = datos['Fecha'].str.extract(r'(\d{4})') # Extrae el año (4 dígitos)
datos['Mes'] = datos['Fecha'].str.extract(r'([a-zA-ZñáéíóúÁÉÍÓÚ]+)') # Extrae el mes

# Convierte el mes al número correspondiente
datos['Mes'] = datos['Mes'].map(meses)

# Convierte a formato datetime asegurando que las columnas sean numéricas
datos['Año'] = pd.to_numeric(datos['Año'], errors='coerce') # Convierte año a número
datos['Fecha'] = pd.to_datetime({'year': datos['Año'], 'month': datos['Mes'], 'day': 1}, errors='coerce')

# Elimina columnas auxiliares específicas sin afectar las demás
datos = datos.drop(columns=['Año', 'Mes'])

# Asegurarse de que la columna 'Fecha' esté en formato datetime y sea el índice
datos['Fecha'] = pd.to_datetime(datos['Fecha'])
datos.set_index('Fecha', inplace=True)

# Suavizar la serie con logaritmo
datos['IPC_log'] = np.log(datos['IPC variación interanual'])


# Dividir los datos en entrenamiento y prueba
train = datos['IPC_log'].iloc[:-18].dropna()
test = datos['IPC_log'].iloc[-18:].dropna()

# Ajuste del modelo SARIMA con los mejores parámetros encontrados (p=2, d=0, q=2, P=1, D=1, Q=0, S=12)
modelo_sarima = SARIMAX(train, order=(2, 0, 2), seasonal_order=(1, 1, 0, 12))
modelo_ajustado_sarima = modelo_sarima.fit(dispatch=False)

# Predicción con los mejores parámetros
predicciones_sarima_log = modelo_ajustado_sarima.forecast(steps=len(test))
predicciones_sarima = np.exp(predicciones_sarima_log)

# Graficar con Plotly
fig = go.Figure()
```

Anexo 4



Anexo 5



Carta de compromiso para asesoría temática

Señores Facultad de Postgrado UNITEC.

Por este medio yo Bayron Alejandro Barahona Álvarez

Identidad No. 08011-1990-21988, Licenciado en ECONOMÍA

Con Maestría en CIENCIAS ACTUARIALES Y FINANCIERAS

Con Doctorado en -----

Hago constar que asumo la responsabilidad de asesorar el trabajo de Tesis de Maestría denominado ANÁLISIS Y ESTIMACIÓN DE LA INFLACIÓN EN HONDURAS MEDIANTE REDES NEURONALES

A ser desarrollado por el (los) estudiante(s): Daniela Alejandra Banegas Suazo

Para lo cual me comprometo a realizar de manera oportuna las revisiones y facilitar las observaciones que considere pertinentes a fin de que se logre finalizar el trabajo de tesis en el plazo establecido por la Facultad de Postgrado.

Nombre: Bayron Alejandro Barahona Álvarez

Número de teléfono/correo electrónico: 3148-6933 /barahona0777cv@hotmail.com

Firma:  _____