



**FACULTAD DE POSTGRADO
TRABAJO FINAL DE GRADUACIÓN**

**ANÁLISIS DE SUAVIZADO DE SERIES TEMPORALES
FINANCIERAS: APLICACIÓN DEL FILTRO DE SAVITZKY-
GOLAY Y UN FILTRO DESARROLLADO LOCALMENTE EN
EL SECTOR FINANCIERO HONDUREÑO**

SUSTENTADO POR:

KEVIN KOSNER PINEDA CASTILLO

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

RECTORA

ROSALPINA RODRÍGUEZ

VICERRECTOR ACADÉMICO NACIONAL

JAVIER ABRAHAM SALGADO LEZAMA

SECRETARIO GENERAL

ROGER MARTÍNEZ MIRALDA

DECANA FACULTAD DE POSTGRADO

ANA DEL CARMEN RETTALLY VARGAS

**ANÁLISIS DE SUAVIZADO DE SERIES TEMPORALES
FINANCIERAS: APLICACIÓN DEL FILTRO DE
SAVITZKY-GOLAY Y UN FILTRO DESARROLLADO
LOCALMENTE EN EL SECTOR FINANCIERO
HONDUREÑO**

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

ASESOR METODOLÓGICO

MARVIN ROBERTO MENDOZA VALENCIA

MIEMBROS DE LA TERNA:

**ALBA GABRIELA GARAY ROMERO
JESÚS RICARDO RODRÍGUEZ RIVERA
DANIEL ANTONIO LUNA RODRÍGUEZ**

DERECHOS DE AUTOR

© Copyright 2025
Kevin Kosner Pineda Castillo

Todos los derechos son reservados.



FACULTAD DE POSTGRADO

ANÁLISIS DE SUAIVIZADO DE SERIES TEMPORALES FINANCIERAS: APLICACIÓN DEL FILTRO DE SAVITZKY-GOLAY Y UN FILTRO DESARROLLADO LOCALMENTE EN EL SECTOR FINANCIERO HONDUREÑO

Kevin Kosner Pineda Castillo

Resumen

Este trabajo de investigación aborda el análisis de series temporales financieras con alta volatilidad mediante la aplicación de dos métodos de filtrado: el filtro de Savitzky-Golay y un filtro utilizando un ajuste por polinomios locales, desarrollado por el Departamento de Estadísticas e Investigación (DEI) de la Comisión Nacional de Bancos y Seguros (CNBS). Se busca evaluar y comparar la efectividad de ambos métodos en la reducción del ruido y la preservación de características clave en las series de datos financieros, optimizando su precisión predictiva. El estudio utiliza técnicas avanzadas como la descomposición de series, el análisis de residuos y la implementación de modelos AR y ARIMA para validar los resultados. Los hallazgos obtenidos son relevantes para mejorar la calidad del análisis financiero y apoyar la toma de decisiones en un entorno financiero dinámico y complejo

Palabras claves: (Savitzky-Golay, filtro polinomio local, series temporales financieras, reducción de ruido, predicciones financieras.)



GRADUATE SCHOOL

**ANÁLISIS DE SUAIVIZADO DE SERIES TEMPORALES
FINANCIERAS: APLICACIÓN DEL FILTRO DE SAVITZKY-
GOLAY Y UN FILTRO DESARROLLADO LOCALMENTE EN
EL SECTOR FINANCIERO HONDUREÑO**

Kevin Kosner Pineda Castillo

Abstract

This research focuses on the analysis of highly volatile financial time series through the application of two filtering methods: the Savitzky-Golay filter and a filter using local polynomial fitting, developed by the Department of Statistics and Research (DEI) of the National Banking and Insurance Commission (CNBS). The study aims to evaluate and compare the effectiveness of both methods in noise reduction and the preservation of key features in financial data series, thereby optimizing their predictive capacity. Advanced techniques such as time series decomposition, residual analysis, and the implementation of AR and ARIMA models are employed to validate the results. The findings are relevant for improving the quality of financial analysis and supporting decision-making in a dynamic and complex financial environment.

Keywords: (Savitzky-Golay, local polynomial filter, financial time series, noise reduction, financial predictions.)

DEDICATORIA

Dedico este trabajo a Dios, quien me ha brindado la sabiduría para superar cada reto en este camino. A mi padre y familiares, por su constante apoyo y sacrificio, enseñándome siempre la importancia del esfuerzo y la perseverancia. A mi prometida, Casi Hernández, por su amor y comprensión incondicional, por acompañarme en cada paso y ser mi motivación diaria. Y a todos aquellos que han creído en mí y me han inspirado a alcanzar esta meta. A ustedes, con profundo cariño y gratitud, les dedico este logro.

AGRADECIMIENTO

Primeramente, quiero agradecer a Dios, por haberme dado la vida y la fortaleza para alcanzar esta meta tan importante en mi vida. A mi familia, especialmente a mi padre, José Santos Pineda, y a mi prometida, Casi Hernández, quienes han sido mi apoyo incondicional a lo largo de todo este proceso de formación. Seguidamente, mi agradecimiento y gratitud a mi asesor de tesis PhD Marvin Mendoza, por su apoyo, paciencia y asesoría en la elaboración de este documento de investigación. También, a mi jefe y amigo, Fredy Vides, por compartir conmigo su conocimiento sobre el tema de investigación, así como su invaluable asesoría en temas profundos de matemáticas y análisis de datos. Finalmente, a mis amigos y a todas las personas que de alguna manera contribuyeron para que este sueño se hiciera realidad. A todos, mi eterno agradecimiento.

Kevin Kosner Pineda Castillo

ÍNDICE DE CONTENIDO

DEDICATORIA	1
AGRADECIMIENTO	2
ÍNDICE DE CONTENIDO	3
ÍNDICE DE FIGURAS.....	8
ÍNDICE DE TABLAS	11
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN	13
1.1 INTRODUCCIÓN	13
1.2 ANTECEDENTES DEL PROBLEMA	15
1.3 DEFINICIÓN DEL PROBLEMA	18
1.3.1 PROBLEMA DE INVESTIGACIÓN	19
1.3.2 DESCRIPCIÓN DEL PROBLEMA.....	19
1.3.3 PREGUNTAS DE INVESTIGACIÓN GENERAL.....	20
1.3.4 PREGUNTAS DE INVESTIGACIÓN ESPECÍFICAS.....	21
1.4 OBJETIVOS DEL PROYECTO.....	21
1.4.1 OBJETIVO GENERAL.....	21
1.4.2 OBJETIVOS ESPECÍFICOS	21
1.5 JUSTIFICACIÓN.....	22
CAPÍTULO II. MARCO TEÓRICO	24
2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL	24
2.1.1 MACROENTORNO.....	26
2.1.2 MICROENTORNO	28
2.2 CONCEPTUALIZACIÓN.....	29
2.3 TEORÍAS DE SUSTENTO	34
2.3.1 BASES TEÓRICAS.....	34
2.3.2 METODOLOGÍAS DESARROLLADAS	35
2.3.3 HERRAMIENTAS UTILIZADOS	37
2.4 MARCO LEGAL.....	39
2.4.1 MARCO LEGAL NACIONAL.....	40
2.4.2 MARCO LEGAL INTERNACIONAL	41
CAPÍTULO III. METODOLOGÍA	42

3.1	CONGRUENCIA METODOLÓGICA.....	42
3.2	MATRIZ METODOLÓGICA	43
3.3	ESQUEMA DE VARIABLES DE ESTUDIO	44
3.3.1	DATOS ABIERTOS CNBS	45
3.4	OPERACIONALIZACIÓN DE LAS VARIABLES.....	47
3.5	HIPÓTESIS.....	48
3.6	ENFOQUE Y MÉTODOS.....	49
3.6.1	ENFOQUE.....	49
3.6.2	ALCANCE.....	50
3.6.3	DISEÑO.....	50
3.7	DISEÑO DE LA INVESTIGACIÓN	50
3.7.1	POBLACIÓN.....	50
3.7.2	MUESTRA	53
3.7.3	TÉCNICAS DE MUESTREO	55
3.8	TÉCNICAS, HERRAMIENTAS Y PROCEDIMIENTOS APLICADOS.....	56
3.8.1	TÉCNICAS	56
3.8.2	HERRAMIENTAS	57
3.8.3	PROCEDIMIENTOS APLICADOS	58
3.8.4	FILTROS APLICADOS.....	58
3.8.5	DESCOMPOSICIÓN DE SERIES DE TIEMPO.....	58
3.8.6	MODELOS DE PREDICCIÓN	58
3.9	FUENTES DE INFORMACIÓN.....	59
3.9.1	FUENTES SECUNDARIAS	59
CAPÍTULO IV. RESULTADOS Y ANÁLISIS		60
4.1	INFORME DE PROCESO DE RECOLECCIÓN DE DATOS	60
4.2	RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS.....	62
4.2.1	ANÁLISIS EXPLORATORIO DE DATOS (EDA)	62
4.2.1.1	ANÁLISIS EDA DE LA CARTERA DE PRÉSTAMOS DE MICROCRÉDITO	
	63	
4.2.1.2	ANÁLISIS EDA DE LA CARTERA DE PRÉSTAMOS, DESTINO	
	INDUSTRIA	63

4.2.1.3	ANÁLISIS EDA DEL SALDO EN DEPÓSITOS	64
4.2.1.4	ANÁLISIS EDA DE TRANSACCIONES DE DEPÓSITOS A CUENTAS DE AHORRO	65
4.3	ANÁLISIS DE LA METODOLOGÍA APLICADA	66
4.3.1	ANÁLISIS DE LA CARTERA DE PRÉSTAMOS DE MICROCRÉDITO DE BANHCAFE	68
4.3.1.1	FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE BANHCAFE.....	68
4.3.1.2	DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA LA SERIE DE BANHCAFE	71
4.3.1.3	MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE BANHCAFE	74
4.3.1.4	MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) PARA LA SERIE DE BANHCAFE.....	76
4.3.2	ANÁLISIS DE LA CARTERA DE PRÉSTAMOS PROMERICA DEL DESTINO INDUSTRIA	79
4.3.2.1	FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE PROMERICA	79
4.3.2.2	DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA PROMERICA.....	83
4.3.2.3	MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DE PROMERICA.....	85
4.3.2.4	MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) PARA LA SERIE DE PROMERICA	87
4.3.3	ANÁLISIS DEL SALDO DE DEPÓSITOS DE LAFISE	90
4.3.3.1	FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE LAFISE.....	90
4.3.3.2	DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA LA SERIE DE LAFISE	93
4.3.3.3	MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DE LAFISE	96
4.3.3.4	MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA)	

PARA LA SERIE DE LAFISE	98
4.3.4 ANÁLISIS DE LAS TRANSACCIONES DE DEPÓSITOS DEL BANCO HONDURAS.....	101
4.3.4.1 FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DEL BANCO HONDURAS.....	101
4.3.4.2 DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA EL BANCO HONDURAS.....	104
4.3.4.3 MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DEL BANCO HONDURAS	107
4.3.4.4 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) DEL BANCO HONDURAS	109
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....	112
5.1 CONCLUSIONES	112
5.2 RECOMENDACIONES	114
CAPÍTULO VI. APLICABILIDAD.....	116
6.1 NOMBRE DE LA PROPUESTA	116
6.2 JUSTIFICACIÓN DE LA PROPUESTA.....	116
6.3 ALCANCE DE LA PROPUESTA	117
6.3.1 OBJETIVO GENERAL DEL PROYECTO.....	117
6.3.2 OBJETIVO ESPECÍFICOS DEL PROYECTO.....	117
6.4 DESCRIPCIÓN Y DESARROLLO	118
6.4.1 DESCRIPCIÓN	118
6.4.1.1 VALIDACIÓN CRUZADA DE LOS MODELOS PREDICTIVOS	119
6.4.2 DESARROLLO	120
6.4.2.1 EXTRACCIÓN Y CONSTRUCCIÓN DE LAS VARIABLES.....	120
6.4.2.2 APLICACIÓN DE LOS FILTROS	121
6.4.2.3 DESCOMPOSICIÓN DE SERIES TEMPORALES.....	123
6.4.2.4 ENTRENAMIENTO DEL MODELO AUTO REGRESIVO (AR).....	125
6.4.2.5 ENTRENAMIENTO DEL MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA).....	126
6.5 MEDIDAS DE CONTROL	127

6.6	CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO	128
6.6.1	TÉCNICA PERT (PROGRAM EVALUATION AND REVIEW TECHNIQUE) 128	
6.6.2	ANÁLISIS DE DIAGRAMAS DE GANTT	129
6.6.3	DESARROLLO DEL CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO	130
6.6.3.1	FICHA TÉCNICA.....	130
6.6.3.2	IMPLEMENTACIÓN DE LA METODOLOGÍA POR LAS ÁREAS INTERESADAS.....	131
6.7	CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA 133	
	REFERENCIAS BIBLIOGRÁFICAS.....	1
	ANEXOS	3
	ANEXO 1: MODELACIÓN MATEMÁTICA DEL FILTRO DE SAVITZKY-GOLAY	3
	ANEXO 2: MODELACIÓN MATEMÁTICA DEL FILTRO DESARROLLADO POR EL DEI	4
	ANEXO 3: FUNCIÓN PARA COMPROBAR ESTACIONALIDAD (PRUEBA DE DICKY-FULLER)	5
	ANEXO 4: FUNCIÓN PARA GENERAR GRÁFICOS ACF Y PACF	6
	ANEXO 5: CURSO PROPEDEÚTICO	7
	ANEXO 6: CURSO DE PYTHON.....	8
	ANEXO 7: CURSO DE INTRODUCCIÓN A MACHINE LEARNING EN PYTHON	9
	ANEXO 8: DIPLOMADO DE ESTADÍSTICA APLICADA	10

ÍNDICE DE FIGURAS

Figura 1. Nube de palabras claves.	29
Figura 2. Diagrama de relación entre las palabras claves	30
Figura 3: Esquema de las Variables de Estudio.....	45
Figura 4: Portal de Datos Abiertos CNBS	46
Figura 5: Organizaciones en Datos Abiertos CNBS.....	46
Figura 6. Proceso de Selección de la Muestra para el Estudio de Variables Financieras.....	55
Figura 7. Diagrama de Recolección, Limpieza, Transformación y Depuración de Datos	62
Figura 8. Saldos de Cartera de Microcréditos por Banco	63
Figura 9. Saldos de Cartera de Destino Industria por Banco	64
Figura 10. Participación de los Depósitos por Banco	65
Figura 11. Número de Transacciones de Depósitos a Cuentas de Ahorro por Banco	66
Figura 12. Aplicación del filtro de Savitzky-Golay a la Serie de Microcréditos BANHCAFE ...	69
Figura 13. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Microcréditos BANHCAFE.....	69
Figura 14. Aplicación del filtro DEI a la Serie de Microcréditos BANHCAFE	70
Figura 15. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Microcréditos BANHCAFE.....	71
Figura 16. Descomposición de Serie Temporal: Microcréditos BANHCAFE.....	72
Figura 17. Descomposición de Serie Temporal: Filtro Savitzky-Golay Microcréditos BANHCAFE.....	72
Figura 18. Descomposición de Serie Temporal: Filtro DEI Microcréditos BANHCAFE	73
Figura 19. Predicción Auto Regresiva: Microcréditos BANHCAFE.....	75
Figura 20. Análisis ACF y PACF: Microcréditos BANHCAFE	77
Figura 21. Predicción ARIMA: Microcréditos BANHCAFE.....	78
Figura 22. Aplicación del filtro de Savitzky-Golay a la Serie del Destino Industria de PROMERICA	80
Figura 23. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie del Destino Industria de PROMERICA.....	81
Figura 24. Aplicación del filtro DEI a la Serie del Destino Industria de PROMERICA	82
Figura 25. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie del	

Destino Industria de PROMERICA.....	82
Figura 26. Descomposición de Serie Temporal: Destino Industria PROMERICA.....	83
Figura 27. Descomposición de Serie Temporal: Filtro Savitzky-Golay Destino Industria PROMERICA	84
Figura 28. Descomposición de Serie Temporal: Filtro DEI Destino Industria PROMERICA	84
Figura 29. Predicción Auto Regresiva: Destino, Industria PROMERICA.....	86
Figura 30. Análisis ACF y PACF: Destino Industria PROMERICA	88
Figura 31. Predicción ARIMA: Destino Industria PROMERICA.....	89
Figura 32. Aplicación del filtro de Savitzky-Golay a la Serie de Saldos de Depósitos para LAFISE.....	91
Figura 33. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Saldos de Depósitos para LAFISE.....	91
Figura 34. Aplicación del filtro DEI a la Serie de Saldos de Depósitos para LAFISE	92
Figura 35. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Saldos de Depósitos para LAFISE	93
Figura 36. Descomposición de Serie Temporal: Saldo de Depósitos de LAFISE.....	94
Figura 37. Descomposición de Serie Temporal: Filtro Savitzky-Golay Saldo de Depósitos de LAFISE.....	94
Figura 38. Descomposición de Serie Temporal: Filtro DEI Saldo de Depósitos de LAFISE	95
Figura 39. Predicción Auto Regresiva: Saldo Depósitos de LAFISE	97
Figura 40. Análisis ACF y PACF: Saldo Depósitos de LAFISE.....	99
Figura 41. Predicción ARIMA: Saldo Depósitos de LAFISE	100
Figura 42. Aplicación del filtro de Savitzky-Golay a la Serie de Transacciones de Depósitos del Banco HONDURAS	102
Figura 43. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Transacciones de Depósitos del Banco HONDURAS.....	103
Figura 44. Aplicación del filtro DEI a la Serie de Transacciones de Depósitos del Banco HONDURAS	103
Figura 45. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Transacciones de Depósitos del Banco HONDURAS.....	104
Figura 46. Descomposición de Serie Temporal: Transacciones de Depósitos del Banco	

HONDURAS	105
Figura 47. Descomposición de Serie Temporal: Filtro Savitzky-Golay Transacciones de Depósitos del Banco HONDURAS	105
Figura 48. Descomposición de Serie Temporal: Filtro DEI Transacciones de Depósitos del Banco HONDURAS	106
Figura 49. Predicción Auto Regresiva: Transacciones de Depósitos del Banco HONDURAS .	108
Figura 50. Análisis ACF y PACF: Transacciones de Depósitos del Banco HONDURAS	109
Figura 51. Predicción ARIMA: Transacciones de Depósitos del Banco HONDURAS.....	110
Figura 52. Selección del conjunto de entrenamiento y de prueba	119
Figura 53. Código: Carga de los datos y aplicación del filtro de Savitzky-Golay.....	122
Figura 54. Código: Función para generar los gráficos de los filtros y residuos.	122
Figura 55. Código: Función que realiza el filtro desarrollado por el DEI.	123
Figura 56. Código: Función que realiza la descomposición de series temporales.....	124
Figura 57. Código: Función del modelo AR.....	125
Figura 58. Código: Función del modelo ARIMA.....	126

ÍNDICE DE TABLAS

Tabla 1. Matriz Metodológica.....	43
Tabla 2. Matriz de Procesos.....	47
Tabla 3. Análisis de Varianza de los Residuos para la Serie de Microcréditos de BANHCAFE	73
Tabla 4. Métricas del Modelo AR: Serie de Microcréditos de BANHCAFE.....	76
Tabla 5. Orden del modelo ARIMA: Microcréditos BANHCAFE	78
Tabla 6. Métricas del Modelo ARIMA: Serie de Microcréditos de BANHCAFE.....	79
Tabla 7. Análisis de Varianza de los Residuos para la Serie de Destino Industria de PROMERICA	85
Tabla 8. Métricas del Modelo AR: Destino, Industria PROMERICA	87
Tabla 9. Orden del modelo ARIMA: Destino, Industria PROMERICA	88
Tabla 10. Métricas del Modelo ARIMA: Serie del Destino Industria de PROMERICA.....	89
Tabla 11. Análisis de Varianza de los Residuos para la Serie de Saldo de Depósitos de LAFISE	96
Tabla 12. Métricas del Modelo AR: Depósitos LAFISE.....	98
Tabla 13. Orden del modelo ARIMA: Depósitos LAFISE.....	99
Tabla 14. Métricas del Modelo ARIMA: Serie de Depósitos de LAFISE	101
Tabla 15. Análisis de Varianza de los Residuos para la Serie de Transacciones de Depósitos del Banco HONDURAS	107
Tabla 16. Métricas del Modelo AR: Transacciones de Depósitos Banco HONDURAS	108
Tabla 17. Orden del modelo ARIMA: Transacciones de Depósitos del Banco HONDURAS ..	110
Tabla 18. Métricas del Modelo ARIMA: Serie de Transacciones de Depósitos del Banco HONDURAS	111
Tabla 19. Selección de variables independiente y dependiente	120
Tabla 20. Métricas de evaluación del modelo AR.....	127
Tabla 21. Métricas de evaluación del modelo ARIMA	128
Tabla 22. Estimaciones de Tiempo PERT: Ficha Técnica	130
Tabla 24. Diagrama de Gantt: Cronograma de Implementación y Presupuesto de la Ficha Técnica	131
Tabla 25. Costos y Duración de los Cursos Ofrecidos por la UNAH.....	132
Tabla 26. Estimaciones de Tiempo PERT: Implementación por las Áreas Interesadas.....	132

Tabla 27. Diagrama de Gantt: Cronograma de Implementación y Presupuesto para las Áreas Interesadas.....	133
Tabla 28. Matriz de concordancia de los segmentos de la tesis con la propuesta	1

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

La investigación busca generar conocimientos nuevos o validar conocimientos ya existentes con la observación, análisis y experimentos. Contribuye al avance de la sociedad al permitir el desarrollo de soluciones y tecnologías que mejoran la calidad de vida y expande el conocimiento humano al resolver problemas, explicar fenómenos y desarrollar teorías. La investigación implica muchos retos, entre ellos está la financiación, limitaciones en las metodologías adecuadas que validen los resultados y la aplicación de los resultados. En conjunto, la investigación enfrenta muchos retos constantes, pero sus aportaciones y beneficios son esenciales para nuestra sociedad.

1.1 INTRODUCCIÓN

El análisis de las variables financieras se ha convertido en un factor crucial para la toma de decisiones informadas para las empresas y entes reguladores. Así mismo, el modelado de predicciones en series de tiempo es una técnica muy utilizada en una gran gama de campos científicos como el análisis financiero, económico, meteorológico entre otros. Consiste en analizar y comprender los patrones de comportamiento de una serie de tiempo que después serán utilizados para hacer predicciones sobre su futuro.

Esta tarea es especialmente importante para el Departamento de Estadísticas e Investigación (DEI) de la Comisión Nacional de Bancos y Seguros (CNBS), ya que un análisis preciso de estas series depende de la calidad de los datos utilizados. Por ello, este trabajo propone seis capítulos con el fin de estructurar el uso de filtros para suavizar los datos financieros, que permitan mejorar la precisión y confiabilidad del análisis en series de tiempo, optimizando los resultados de las predicciones y facilitando decisiones informadas en el ámbito financiero.

En el Capítulo 1, se encuentra una definición general del trabajo de investigación,

incluyendo las preguntas de investigación, los objetivos y la justificación del porqué el uso de un filtro es una solución para mejorar el análisis de series de tiempo y como este trabajo servirá de apoyo a las áreas que lo necesiten de la CNBS.

El Capítulo 2 proporciona el marco teórico de la investigación, profundizando en los principios y conceptos clave relacionados con el uso de filtros y metodologías de predicción. Este capítulo revisa la literatura actual sobre la situación del tema, abordando la conceptualización y las metodologías desarrolladas para aplicar filtros en el análisis de series de tiempo.

En el Capítulo 3 presenta la metodología usada en la investigación para la implementación del filtro de Savitzky-Golay y el filtro por Ajuste de Polinomios Locales desarrollado por el Departamento de Estadísticas e Investigación. Se analiza el diseño, los métodos utilizados para el procesamiento de los datos utilizados.

El Capítulo 4 describe el análisis exploratorio de los datos, presentando los hallazgos de la investigación y detallando las mejoras obtenidas al implementar los filtros descritos en el capítulo anterior. Estos resultados se contrastan con los objetivos, preguntas y marco teórico establecidos en el presente trabajo de investigación.

En el Capítulo 5 se describen las conclusiones y recomendaciones de los resultados de la investigación, para identificar las limitaciones y viabilidad en la implementación de la metodología propuesta. Según las conclusiones identificadas se redactan recomendaciones teóricas y prácticas para que el Departamento de Estadísticas e Investigación continúe en temas de investigación referentes al uso de filtros para suavizar series de tiempo con una alta volatilidad.

El Capítulo 6 describe la aplicabilidad de la propuesta de implementación, se exhiben los objetivos, como el desarrollo de la propuesta y por último se presenta un cronograma de

implementación, así como el presupuesto.

1.2 ANTECEDENTES DEL PROBLEMA

La Comisión Nacional de Bancos y Seguros (CNBS), es una entidad descentralizada de la Presidencia de la República, oficialmente establecida el 10 de junio de 1996 por el Dr. Carlos Roberto Reina, entonces presidente Constitucional de la República de Honduras. La misión institucional de la Comisión es la de velar por la estabilidad, solvencia, regulación, supervisión y control del sistema financiero hondureño. También, vigila la transparencia y respeto a los derechos de los usuarios financieros.

Con el fin de salvaguardar el interés público y con la visión de convertirse en una entidad referente en regulación y supervisión en Centroamérica, la Comisión Nacional de Bancos y Seguros aplica las mejores prácticas internacionales en el análisis de la situación financiera de las instituciones bajo su supervisión. Estos análisis abarcan estudios financieros, económicos, matemáticos y estadísticos que van desde metodologías simples, como análisis de tendencia central y dispersión, hasta modelos econométricos avanzados y proyecciones. En este contexto, las series financieras son abordadas y tratadas como series de tiempo para obtener proyecciones precisas y comprender mejor el comportamiento de las variables financieras a lo largo del tiempo.

Dentro del panorama financiero, las series temporales suelen ser altamente volátiles y no estacionarias, esta naturaleza impredecible hace que capturar patrones y tendencias sea una tarea difícil sin comprometer las características esenciales de los datos financieros. Los modelos clásicos como AR, ARMA y ARIMA, aunque son ampliamente utilizados en el análisis de series temporales, tienen limitaciones significativas en este contexto, además, son sensibles a valores atípicos en los datos, lo que puede afectar negativamente su capacidad para hacer predicciones precisas en las series financieras. En un entorno tan dinámico como el mercado financiero, donde

los eventos inesperados pueden tener un impacto significativo, la presencia de valores atípicos puede distorsionar los resultados de estos modelos y llevar a proyecciones poco fiables.

(Fernando Moreno Pino, 2023) describe:

Los primeros modelos estadísticos realizaron aproximaciones con el propósito de resolver el problema de predicción de las series temporales aplicando una familia de modelos autorregresivos de media móvil (Auto Regressive Moving Average), ARMA con sus siglas en inglés fueron introducidos a finales del siglo XX, como una combinación de los modelos Auto Regressive (AR) y modelos de medias móviles (Moving Average, MA en inglés). Estos modelos capturan la dinámica de una serie temporal al considerar la dependencia que existe entre valores de la serie temporal en diferentes puntos del tiempo, esa dependencia es conocida como la autocorrelación. (p.10)

Según el libro “Time Series Analysis With Applications in R” de Cryer y Chan (Jonathan D. Cryer Kung-Sik Chan, 2008) “Los modelos ARMA y ARIMA fueron desarrollados en la década de 1960 por George Box y Gwilym Jenkins, quienes publicaron un libro seminal sobre el tema en 1970” (p.vii). Los modelos ARMA son utilizados para modelar series temporales estacionarias, por otro lado, los modelos ARIMA incluyen un término de diferenciación para convertir las series no estacionarias a estacionarias, dicho término puede ser complejo de seleccionar.

Esta investigación busca explorar la implementación de métodos más avanzados como el uso del filtrado de series temporales financieras, estos filtros ofrecen una mayor flexibilidad en modelado de los datos permitiendo una mejor adaptación a patrones no lineales, ayudan a la identificación de tendencias y características subyacentes de manera más precisa. Además, los filtrados pueden ser diseñados para ser menos sensibles a valores atípicos, lo que mejora su

capacidad para proporcionar pronósticos más precisos en entornos financieros volátiles.

Según el libro de “ Cálculo diferencial e integral” de Ayres, (Ayres, 1991) “en el análisis matemático el máximo y el mínimo de una función es el menor y mayor valor que toma la función, generalmente se conocen valores extremos” (p,42). Lo que motivó a Savitzky fue la ubicación de estos valores extremos en curvas de datos experimentales debido a las dificultades que enfrentaba al analizar datos de espectroscopia (Abraham Savitzky, 1989). En este campo, la identificación precisa de picos y valles en los espectros es crucial para la interpretación de la composición química de una muestra, Savitzky propuso un método alternativo basado en el ajuste de mínimos cuadrados de polinomios a segmentos de los datos.

Marcel J. E. Golay fue un matemático e ingeniero suizo que colaboró con Abraham Savitzky en el desarrollo del método para la ubicación de máximos y mínimos en curvas de datos experimentales (Abraham. Savitzky y Golay, 1964). Golay fue responsable de la base matemática del método, incluyendo la derivación de las ecuaciones para el ajuste de mínimos cuadrados de polinomios a segmentos de datos, realizó un análisis exhaustivo de las propiedades del método, como su sensibilidad al ruido y la elección del grado del polinomio ([Ver Anexo 1](#)).

(Schafer, 2011) afirma que:

Savitzky y Golay propusieron un método de suavizado de datos basado en una aproximación polinómica de mínimos cuadrados locales. Demostraron que ajustar un polinomio a un conjunto de muestras de entrada y luego evaluar el polinomio resultante en un único punto dentro del intervalo de aproximación es equivalente a una convolución discreta con un valor fijo (p. 1).

El filtro de Savitzky-Golay reduce el ruido manteniendo las características principales

(forma y altura de los picos) de las series de tiempo. Según (Larive y Sweedler, 2013) “el artículo de Savitzky y Golay publicado en 1964 es uno de los más citados en la revista *Analytical Chemistry* y está clasificado por esa revista como uno de sus "diez artículos seminales””(párr. 9).

En síntesis, en esta tesis, exploramos el uso del filtro de Savitzky-Golay, una técnica de suavizado de señales que fue desarrollada por los científicos Abraham Savitzky y Marcel J. E. Golay en la década de 1960 (Abraham-Savitzky, 1989). Desde entonces, el filtro de Savitzky-Golay ha sido objeto de numerosos estudios y mejoras, lo que ha llevado a su amplia adopción en diversas disciplinas científicas y tecnológicas. Su capacidad para preservar características importantes de la señal mientras se reduce el ruido la hace especialmente útil en aplicaciones donde es crucial extraer información precisa de conjuntos de datos contaminados con ruido.

1.3 DEFINICIÓN DEL PROBLEMA

En el contexto de la CNBS (Comisión Nacional de Bancos y Seguros) como ente regulador financiero, uno de los problemas comunes con las series de tiempo financieras es la presencia de ruido o fluctuaciones aleatorias que pueden dificultar la identificación de tendencias subyacentes o patrones significativos en los datos. Una de las características más relevantes de las variables financieras es que su volatilidad cambia con el tiempo, generando señales con ruido cuya frecuencia sin ruido es grande a lo largo del tiempo.

El Departamento de Estadísticas e Investigación (DEI) de la Comisión Nacional de Bancos y Seguros ha desarrollado un filtro con una sólida base matemática con el fin de poder suavizar las series temporales, mediante el uso del ajuste por polinomios locales de grado determinado y un tamaño de ventana específico. Esta estructura permite que los datos en los extremos también sean suavizados, mitigando así los efectos de los bordes en el análisis ([Ver Anexo 2](#)). Cabe señalar que, aunque el artículo que expone detalladamente la base matemática del filtro se encuentra en fase de

desarrollo para su publicación, su teoría y sustento matemático ya están completamente establecidos, este artículo en desarrollo servirá como respaldo para la aplicación y validación de esta metodología.

El problema que se busca resolver mediante el uso del filtro de Savitzky-Golay y del filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI) en series temporales financieras es mejorar la precisión y la interpretabilidad de los datos al reducir el ruido y destacar las tendencias subyacentes. Estos filtros ayudan a suavizar las fluctuaciones no deseadas en las series temporales financieras, preservando características importantes, como picos o cambios abruptos, mientras eliminan el ruido. Esto permite una visualización más clara de las tendencias subyacentes y reduce la interferencia del ruido en el análisis, facilitando la interpretación de los datos financieros y la toma de decisiones informadas en áreas como la inversión, el riesgo financiero y la regulación bancaria.

1.3.1 PROBLEMA DE INVESTIGACIÓN

El Departamento de Estadísticas e Investigación (DEI) de la CNBS ha identificado que, en diversas áreas de análisis, es esencial contar con métodos de filtrados que permitan obtener información confiable y relevante, para lograr una representación más clara y precisa de las tendencias y características subyacentes en las series temporales.

1.3.2 DESCRIPCIÓN DEL PROBLEMA

El análisis de datos financieros en el ámbito de la supervisión bancaria exige una alta precisión para poder extraer patrones y tendencias que sirvan de orientación para las decisiones estratégicas. Sin embargo, la mayoría de las series temporales, que son de gran relevancia en este tipo de análisis, suelen presentar volatilidad significativa y ruido, lo que dificulta la identificación de comportamientos subyacentes, que en muchos casos no reflejan el comportamiento real de los

indicadores.

Actualmente, el Departamento de Estadísticas e Investigación (DEI) enfrenta el reto de encontrar una metodología que permita suavizar estas series temporales sin perder información crucial en la señal, especialmente en puntos críticos como picos y cambios abruptos. Los métodos de suavizado tradicionales, como los promedios móviles, suelen suavizar los datos de forma excesiva, eliminando o atenuando estos detalles relevantes, lo que resulta en una representación menos precisa de la realidad.

En respuesta a esta problemática, se plantea el uso del filtro de Savitzky-Golay y del filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI), que tienen la capacidad de reducir el ruido en los datos manteniendo la integridad de la estructura de la señal, aplicando un ajuste de polinomios a través de una ventana de datos obteniendo una representación más efectiva y fiel de los datos financieros. Su implementación adecuada podría optimizar la calidad del análisis de las series temporales, mejorar la precisión en la toma de decisiones y permitir una interpretación más acertada de las tendencias financieras.

De esta manera, el problema radica en encontrar una configuración adecuada del filtro de Savitzky-Golay (grado del polinomio y tamaño de ventana), además de comparar su eficiencia con el filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI). Esto permitirá lograr una correcta reducción de ruido sin comprometer los detalles críticos de la señal, optimizando así su aplicación en el análisis de series temporales financieras dentro de la Comisión Nacional de Bancos y Seguros.

1.3.3 PREGUNTAS DE INVESTIGACIÓN GENERAL

¿De qué manera la aplicación del filtro de Savitzky-Golay y del filtro desarrollado por el Departamento de Estadísticas e Investigación de la CNBS, en comparación con el análisis de las

variables sin filtrar, mejora la precisión de las predicciones en series temporales financieras?

1.3.4 PREGUNTAS DE INVESTIGACIÓN ESPECÍFICAS

1. ¿Cuál es la configuración óptima de los filtros en términos de grado del polinomio y tamaño de ventana para el análisis de series temporales financieras?
2. ¿Qué tan efectiva es la aplicación del filtro de Savitzky-Golay en comparación con el filtro desarrollado por el Departamento de Estadísticas e Investigación de la CNBS en la reducción de ruido sin pérdida de detalles críticos en la señal?
3. ¿Cuál es el impacto de la descomposición de una serie en la detección de anomalías en series temporales?

Explorar estas cuestiones proporcionará perspectivas valiosas que fortalecerán la comprensión y el análisis de las series temporales financieras, particularmente aquellas caracterizadas por una alta volatilidad, permitiendo una toma de decisiones más informada y precisa en entornos financieros dinámicos y complejos.

1.4 OBJETIVOS DEL PROYECTO

1.4.1 OBJETIVO GENERAL

Analizar y mejorar el análisis de series temporales financieras altamente volátiles mediante el uso del filtro de Savitzky-Golay y el filtro desarrollado por Departamento de Estadísticas e Investigación (DEI), con el fin de fortalecer la capacidad de tomar decisiones informadas en entornos financieros dinámicos y complejos.

1.4.2 OBJETIVOS ESPECÍFICOS

1. Evaluar el impacto de los filtros en la reducción de ruido y la preservación de características importantes en series temporales financieras con alta volatilidad.

2. Comparar el rendimiento entre los filtros propuestos para el análisis de series en términos de precisión en la detección de tendencias y la predicción de comportamientos futuros en series temporales financieras altamente volátiles.
3. Identificar y optimizar los parámetros de los filtros para maximizar su eficacia en el análisis de series temporales financieras caracterizadas por una alta volatilidad.

1.5 JUSTIFICACIÓN

Para el análisis y mejora de series temporales financieras altamente volátiles mediante el uso del Filtro de Savitzky-Golay y desarrollado por el Departamento de Estadísticas e Investigación (DEI) de la CNBS se apoya en la necesidad de robustecer la herramienta analítica utilizada en el ámbito financiero, que permita abordar la complejidad y dinámica inherente a las series temporales caracterizadas por una alta volatilidad. En los mercados financieros, donde la volatilidad es constante, la capacidad de identificar y comprender las tendencias subyacentes en los datos temporales es clave para la toma de decisiones y para la gestión eficaz del riesgo. Por desgracia, las fluctuaciones repentinas y el ruido aleatorio en las series temporales financieras pueden dificultar la predicción precisa de los movimientos del mercado y reducir la información significativa.

El filtro de Savitzky-Golay ha surgido como una herramienta prometedora en el campo particular del análisis de series de tiempo, ofreciendo una forma de suavizar las fluctuaciones no deseadas en los datos mientras se mantienen las características de interés. Así mismo, el Departamento de Estadísticas e Investigación (DEI) de la CNBS ha desarrollado un filtro que al igual que el filtro de Savitzky-Golay tiene el potencial de mejorar significativamente la precisión, interpretabilidad y capacidad de los datos, con alta frecuencia permitiendo un mejor entendimiento de las tendencias del mercado y una toma de decisiones más fundamentada. La necesidad de

explorar y evaluar el impacto de los filtros en el análisis de series temporales financieras con alta volatilidad es un tema importante.

Esta investigación busca obtener “insights” valiosos para fortalecer el análisis financiero y desarrollar herramientas analíticas más sofisticadas que se adapten a las demandas de un entorno financiero complejo y cambiante. Los filtros propuestos utilizan una técnica matemática para suavizar los datos y eliminar el ruido, lo que hace que sea más fácil identificar las tendencias subyacentes en la serie temporal financiera. Además, esta investigación también contribuirá al desarrollo de herramientas analíticas más avanzadas que se adapten a las necesidades de un entorno financiero cada vez más complejo y dinámico.

CAPÍTULO II. MARCO TEÓRICO

El marco teórico es una parte fundamental de cualquier investigación ya que proporciona una base conceptual y científica sobre el tema de estudio, este capítulo realiza una revisión exhaustiva de conceptos, teorías, antecedentes y estudios previos que están relacionados con el problema de investigación. Su propósito es situar el estudio dentro de un contexto más amplio, identificar los enfoques teóricos relevantes y servir como guía para el análisis de los datos, también permite al investigador justificar la elección de un determinado enfoque o método, al conectar la investigación actual con el conocimiento existente, asegurando que el estudio esté bien fundamentado.

2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL

En la actualidad, el análisis de series temporales financieras en la Comisión de Bancos y Seguros se ha centrado principalmente en el uso de modelos auto regresivos como ARMA (Autoregressive Moving Average) y ARIMA (Autoregressive Integrated Moving Average). Estos modelos han sido ampliamente utilizados para analizar y predecir el comportamiento de variables financieras a lo largo del tiempo.

Los modelos son una herramienta útil para analizar y predecir tendencias financieras, ayudan a gestionar el riesgo y tomar decisiones más informadas. Los procesos financieros usualmente muestran un comportamiento no lineal y complejo lo que ha planteado en la actualidad una serie de desafíos en el manejo, elaboración de modelos y predicciones precisas. Según (FUENTES, 2020), “La no linealidad es, pues una condición necesaria para la complejidad”. Por lo que se ha vuelto necesario explorar enfoques más avanzados y eficientes para el análisis de series temporales financieras. En este contexto, el filtro de Savitzky–Golay ha surgido como una técnica prometedora como método de suavizado de datos, este filtrado se basa en ajustar

polinomios locales a puntos cercanos en una serie temporal, lo que permite eliminar el ruido y resaltar tendencias subyacentes de manera efectiva.

En el año 2023 la CNBS, en busca de fortalecer el campo de la investigación se creó el Departamento de Estadísticas e Investigación (DEI), donde su función principal es la investigación de modelos matemáticos, financieros y económicos que ayuden a fortalecer la toma de decisiones institucionales y asesorar a las diferentes unidades de la Comisión Nacional de Bancos y Seguros, con información, datos estadísticos, indicadores, análisis y evaluaciones acerca del sistema financiero nacional. El Departamento de Estadísticas e Investigación (DEI) desarrolla propuestas y diseños de metodologías de investigación para el análisis y evaluación de normativas y políticas, en el marco de las atribuciones de la Comisión Nacional de Bancos y Seguros.

En este escenario, el Departamento de Estadísticas e Investigación (DEI) dentro de sus muchas propuestas de modelado de datos, ha propuesto el empleo del filtrado de Savitzky–Golay y el filtro por Ajuste de Polinomios Locales desarrollado por el mismo departamento, como técnicas de suavizado de datos para reducir el ruido presente en las series temporales financieras que exhiben una volatilidad no deseada. Esta volatilidad dificulta la interpretación de las características fundamentales de la serie temporal, lo que resalta la necesidad de aplicar métodos de filtrado eficaces para mejorar la calidad y la interpretabilidad de los datos financieros. Aunque el filtrado de Savitzky–Golay ha sido propuesto y utilizado en diversas áreas durante hace un tiempo en el contexto nacional específicamente aplicada a series temporales financieras, es poco conocida en Honduras. Esta situación promueve la oportunidad de explorar y difundir el uso de este método en el ámbito financiero del país, ya que podría ofrecer beneficios significativos en términos de mejora de la calidad de los datos y facilitar la interpretación de las características clave de las series temporales financieras.

En las secciones siguientes abordaremos cómo la aplicación del filtro de Savitzky–Golay y el filtro por Ajuste de Polinomios Locales desarrollado por el DEI puede ayudar a mitigar estos problemas e identificar las tendencias subyacentes en la serie temporal financiera.

2.1.1 MACROENTORNO

En el contexto del actual macroentorno, caracterizado por un rápido avance tecnológico y un uso creciente de datos, los filtros de suavizado han adquirido gran relevancia por su capacidad para procesar señales y series temporales complejas. La abundante disponibilidad de datos exige que las organizaciones puedan extraer información útil de grandes volúmenes de datos de manera eficiente. La implementación del filtro de Savitzky-Golay en algoritmos de procesamiento de datos contribuye a identificar patrones y tendencias ocultas, lo que facilita una toma de decisiones más informada, resultando especialmente crucial en aplicaciones de machine learning y análisis predictivo, donde la calidad de los datos de entrada es determinante para el rendimiento de los modelos.

Con el aumento en la cantidad de datos provenientes de sensores, instrumentos científicos, y fuentes financieras, la necesidad de herramientas eficaces para la reducción de ruido y suavizado de datos es más importante que nunca. A nivel global, las aplicaciones del filtro de Savitzky-Golay se han expandido a varias áreas clave.

(Dombi y Dineva, 2020), en un estudio realizado en la Universidad de Szeged, Hungría, explican que el procesamiento de señales de electromiografía (EMG) es fundamental en diversas aplicaciones del campo biomédico. En este estudio, se aplicó el filtro Savitzky-Golay a una señal EMG contaminada con ruido blanco gaussiano aditivo (AWGN), con el objetivo de eliminar el ruido y mejorar la calidad de la señal. La efectividad del filtro se evalúa mediante la mejora en la relación señal-ruido (SNR), demostrando así su capacidad para reducir el ruido sin perder detalles

importantes de la señal original.

(Niedźwiecki et al., 2021) explica el uso del algoritmo Savitzky-Golay, lo que permite abordar problemas donde los sistemas FIR (Finite Impulse Response) presentan cambios dinámicos. Gracias a una técnica de pre estimación reciente, el problema de identificación de sistemas FIR no estacionarios se transforma en un problema de suavizado de los pre estimados generados para los parámetros del sistema. Este estudio realizado en la Universidad Tecnológica de Gdańsk en Polonia, permite aplicar el filtro Savitzky-Golay para rastrear de manera efectiva los cambios en los parámetros del sistema a lo largo del tiempo.

En Corea del Sur, ((Jongwoo Baek et al., 2022), en colaboración con la Universidad Nacional de Seúl, emplearon el filtro de Savitzky-Golay para suavizar los datos de series temporales de concentración de polvo. Mejoraron la calidad de la señal al reducir el ruido sin distorsionar significativamente las características esenciales de la señal. Esto es particularmente importante para la medición de contaminantes como el PM2.5, ya que permite obtener una representación más precisa de las variaciones en la calidad del aire.

Por lo anterior, el uso del filtro de Savitzky-Golay para suavizar datos se ha vuelto esencial en múltiples campos, dado su potencial para mejorar la calidad de las señales en diversas aplicaciones. Desde el análisis de señales biomédicas hasta la monitorización ambiental y el modelado financiero, este filtro permite extraer información más precisa y confiable al reducir el ruido sin comprometer los detalles importantes de las señales, esta capacidad lo posiciona como una herramienta clave en el contexto actual, donde el análisis de grandes volúmenes de datos y la precisión en la identificación de patrones son fundamentales para una toma de decisiones más efectiva y basada en evidencia.

2.1.2 MICROENTORNO

El uso de filtros de suavizado como el filtro de Savitzky-Golay aún es limitado y no se dispone de información específica sobre su uso en Centroamérica. Sin embargo, este filtro se ha utilizado en diversas investigaciones en países de habla hispana. Por ejemplo, en México, con el apoyo y financiamiento del Tecnológico Nacional de México, (Sergio Iván Padrón Ortega, Ernestina Elizabeth Banda-Cruz, Nohra Violeta Gallardo-Rivas, 2023) llevaron a cabo un estudio utilizando el filtro de Savitzky-Golay al procesamiento de espectros derivados de soluciones de asfaltenos, estas mezclas se caracterizan por su complejidad, un desafío significativo en la refinación, producción y transporte del petróleo. Este estudio busca mejorar la calidad de las señales y permitiendo la identificación de componentes y estructuras presentes en estos compuestos.

En el contexto de Honduras, el uso de filtros de suavizado como el filtro de Savitzky-Golay aún es limitado y no ha sido ampliamente documentado en estudios locales específicos. Dado el interés creciente en análisis de datos en instituciones financieras y de investigación, como el Banco Central de Honduras y la Comisión Nacional de Bancos y Seguros (CNBS), existe un potencial significativo para su aplicación en el análisis de series temporales económicas y financieras.

Desde la creación del Departamento de Estadísticas e Investigación (DEI) en 2023 ha buscado las mejores prácticas internacionales en el uso de metodologías para analizar datos financieros, dentro de esas prácticas se ha venido estudiando el uso de filtros de suavizado, incluyendo la evaluación del filtro de Savitzky-Golay como herramienta para tratar datos con alta volatilidad y ruido. Así mismo, el departamento ha creado un filtro usando un Ajuste por Polinomios Locales de grado determinado y en un tamaño de ventana específica permitiendo que los datos en los extremos también sean suavizados.

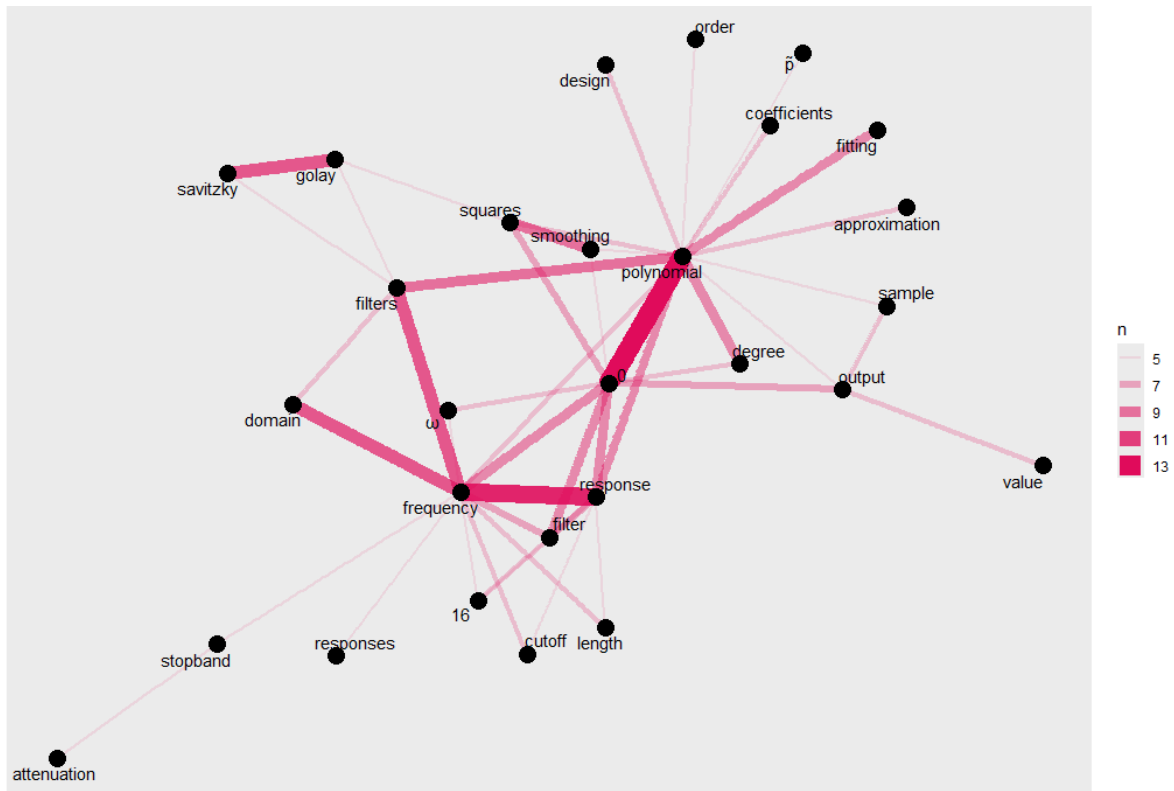


Figura 2. Diagrama de relación entre las palabras claves

Fuente: (Elaboración Propia, 2024)

Filtrado: En el ámbito de las series temporales se refiere al proceso de aplicar técnicas o métodos para suavizar los datos y reducir el ruido presente en la serie temporal. El objetivo principal del filtrado es mejorar la interpretabilidad de la serie al eliminar las fluctuaciones aleatorias y resaltar las tendencias o patrones subyacentes.

Ruido: En el contexto de las series de tiempo financieras, el ruido se refiere a las fluctuaciones aleatorias o no sistemáticas presentes en los datos, que no contienen información significativa ni relevante para el análisis, modelado o interpretación de la serie. Este ruido puede surgir de diversas fuentes, como errores de medición, anomalías en la recolección de datos, factores externos impredecibles (por ejemplo, eventos geopolíticos o desastres naturales), y señales

subyacentes con variaciones aleatorias o dinámicas fundamentales del mercado financiero.

Serie Temporal: Una serie temporal es una secuencia de N datos ordenados y equidistantes en el tiempo, puede ser una serie univariante o multivariante en diferentes momentos. (José Alberto Mauricio, 2007)

Variable Financiera: Una variable financiera se refiere a cualquier cantidad o medida cuantificable que se utiliza para analizar, evaluar o gestionar aspectos relacionados con las finanzas de una empresa, entidad o individuo.

Comisión Nacional de Bancos y Seguros (CNBS): Es una entidad descentralizada de la Presidencia de la República, con independencia funcional, la Comisión supervisa las actividades financieras, de seguros, provisiones, de valores y demás relacionadas con el manejo, aprovechamiento e inversión de los recursos captados del público. Tiene la responsabilidad de velar por la estabilidad y solvencia del sistema financiero y demás supervisados, su regulación, supervisión y control. (Comisión Nacional de Bancos y Seguros, 2024)

Departamento de Estadísticas e Investigación (DEI): Unidad funcional de la Gerencia de Estudios Económicos de la Comisión Nacional de Bancos y Seguros (CNBS), es la unidad encargada de promover y llevar a cabo análisis estadísticos y de investigación en los campos de matemática financiera y económica.

Banco: Institución que presta servicios financieros, estos servicios incluyen la recepción de depósitos, la concesión de préstamos, transferencias de fondos, cambio de divisas, etc.

Variable Financiera: Una variable financiera es una medida cuantitativa que representa un valor o aspecto financiero o económico de una institución en un periodo específico del tiempo. Para la presente investigación se definieron las siguientes variables financieras:

Préstamos: Es la cantidad de dinero que se le ha otorgado a un prestatario, por una institución financiera.

Depósitos: Los depósitos son fondos que los clientes colocan en una cuenta en una institución financiera.

Transacciones de Depósitos (Cuenta de Ahorro): Son las operaciones financieras que implican las transferencias de dinero hacia una cuenta de ahorro en una institución financiera.

Filtro Savitzky–Golay: Este filtro se puede entender como una media móvil generalizado, su cálculo se emplea al derivar los coeficientes del filtro realizando un ajuste por mínimos cuadrados lineales no ponderados con una ventana de filtrado y con un polinomio de determinado grado. (*Filtrar Y Suavizar Datos - MATLAB & Simulink, 2024*)

Filtro DEI: Este filtro fue desarrollado por el Departamento de Estadísticas e Investigación, usa un ajuste por polinomios locales de grado determinado y un tamaño de ventana específico para suavizar los datos.

Modelo AR: El modelo auto regresivo (AR, por sus siglas en inglés) es un modelo de series temporales que se basa en la relación lineal entre los valores pasados de la serie y el valor actual.

Modelo ARIMA: El modelo ARIMA es una generalización del modelo AR que también incorpora un componente de diferenciación para hacer que la serie temporal sea estacionaria y un componente de media móvil (MA) para modelar los errores.

Descomposición de Series Temporales: La descomposición de series temporales es un proceso que consiste en dividir una serie temporal en componentes individuales para entender mejor los patrones subyacentes. Estos componentes generalmente incluyen tendencia,

estacionalidad y ruido.

Convolución: En matemáticas la convolución es una operación matemática en dos funciones que produce una tercera función. Se define como la integral del producto de las dos funciones después de que una se refleja sobre el eje y se desplaza.

Distribución Normal: Es una distribución de probabilidad que se caracteriza por su forma simétrica en forma de campana y es descrita por los parámetros como la media y desviación estándar.

Error de Filtrado o Residuos: En términos de filtrado nos referiremos al error de filtrado o residuo como la diferencia entre la serie original y la serie filtrada, su fórmula es la siguiente:

$$Residuo = Y_{original} - Y_{filtrada}$$

Varianza: La varianza es una medida estadística que mide cuánto se alejan los datos de su valor promedio, es decir, qué tan dispersos están los valores en una distribución.

Error Cuadrático Medio (ECM o MSE): Es una medida utilizada para evaluar el rendimiento de los modelos AR y ARIMA, mide la diferencia promedio entre los valores predichos y los valores reales.

Raíz del Error Cuadrático Medio (RMSE): Es simplemente la raíz cuadrada del MSE y mide la desviación estándar de los errores de predicción, un RMSE bajo indica una mejor precisión en las predicciones.

Error Absoluto Medio (MAE): Mide la magnitud promedio de los errores absolutos, esta medida es más robusta frente a valores atípicos, es utilizada para evaluar el rendimiento de los modelos AR y ARIMA.

Error Porcentual Absoluto Medio (MAPE): Esta medida proporciona el error de predicción como un porcentaje, lo que facilita la comparación entre diferentes series o variables con diferentes escalas en los modelos AR y ARIMA.

Python: Es un lenguaje de programación de código abierto utilizado ampliamente en el desarrollo de aplicaciones web, softwares, la ciencia de datos y el machine learning (ML). Python fue creado por Guido van Rossum en 1991 y se trata de un lenguaje orientado a objetos, fácil de interpretar y con una sintaxis que permite leerlo de manera semejante a como se lee el inglés. (Amazon Web Services, Inc., 2024)

2.3 TEORÍAS DE SUSTENTO

2.3.1 BASES TEÓRICAS

Para abordar el problema, es crucial analizar y comprender las tendencias y patrones de los datos financieros a lo largo del tiempo, esto implica el uso de la teoría de Series de Tiempo, que se enfoca en el estudio y análisis de datos en función del tiempo.

El método de los mínimos cuadrados consiste en la obtención de un hiperplano de forma que se minimice la suma de los cuadrados de las distancias entre cada una de las observaciones de la variable y dicho hiperplano a esta distancia se le conoce como residuos. (Vicente Chirivella González, 2015). La idea en general es encontrar una recta o hiperplano si son más de tres variables explicativas que pasen lo más cerca posible de todos los puntos.

(Baba et al., 2024) menciona que los filtros de suavizado polinómico digital de mínimos cuadrados, popularizados por Savitzky-Golay, se utilizan ampliamente para el procesamiento de señales que tienen una mala calidad y contienen altos porcentajes de ruido aleatorio o sistemático que dificultan la identificación de patrones y tendencias. El filtro de Savitzky-Golay ha sido implementado en muchos campos, específicamente en señales biomédicas generalmente conocidas

como no estacionarias, las electroencefalograma y electrocardiograma.

(Abraham. Savitzky y Golay, 1964). En el filtro de Savitzky-Golay, la ventana de ajuste juega un papel crucial en la determinación de las propiedades del filtro y su rendimiento. El tamaño de la ventana define el número de puntos de datos que se utilizan para ajustar la función polinomial, una ventana más grande sugiere una mejor suavización del ruido, pero también puede producir un retardo en la señal. Por otro lado, un valor de la ventana más pequeño preserva de mejor manera la forma de la señal original, pero puede ser menos efectivo para eliminar el ruido.

(Schafer, 2011) explica que los coeficientes de filtro se calculan durante el proceso de ajuste del polinomio y determinan cómo se ponderan los puntos de la ventana para obtener el valor suavizado en un punto específico, estos coeficientes dependen del orden del polinomio y del tamaño de la ventana.

(Baba et al., 2024) también menciona que los filtros de Savitzky-Golay se construyen para ajustar un polinomio a una porción de ventana de la señal, el ajuste es mediante el método de mínimos cuadrados, donde posteriormente se reemplaza el punto central de la ventana con el valor del polinomio para producir una salida suavizada.

Savitzky y Golay propusieron un método de suavizado de datos basados en una aproximación polinómica de mínimos cuadrados, ambos demostraron que ajustar un polinomio a un conjunto de muestras de entrada y luego evaluar el polinomio resultante. (Schafer, 2011)

2.3.2 METODOLOGÍAS DESARROLLADAS

(Ayres, 1991; *Filtrar Y Suavizar Datos - MATLAB & Simulink*, 2024) menciona varios métodos de filtrado y suavizado de datos entre ellos el filtro de media móvil que suaviza los datos sustituyendo cada punto de datos por el promedio de los puntos de datos vecinos definidos dentro

del lapso de tiempo que especifica cuántos puntos de datos se incluirán en el cálculo del promedio.

También menciona el método de suavizado mediante Regresión Local que calcula las ponderaciones de regresión para cada punto de los datos en un intervalo, donde el valor predictivo está asociado al valor de respuesta a suavizar. Los vecinos más cercanos se definen según el intervalo y la distancia en la abscisa, desde el valor de predicción hasta el valor más distante dentro del intervalo.

Por último, menciona que la Regresión Local Robusta se utiliza cuando los datos contienen valores atípicos que pueden distorsionar el comportamiento general de la tendencia. Para abordar este problema, se aplica un proceso de suavizado robusto que minimiza el impacto de estos valores atípicos en el análisis, implica calcular ponderaciones adicionales, derivadas de los residuos obtenidos durante el suavizado por Regresión Local, estas ponderaciones se ajustan mediante una función bicuadrada, lo que permite asignar un peso adecuado a cada punto de datos, reduciendo la influencia de los valores atípicos. Si el residuo de un punto de datos es pequeño, se le asigna una ponderación cercana a uno, contribuyendo plenamente al suavizado y si el residuo es elevado, la ponderación se aproxima a cero, excluyendo ese punto del cálculo y protegiendo así la tendencia de las distorsiones causadas por los valores atípicos.

(Ortiz Bravo, V. A., Nieto Arias, M. A., & Castañeda Cardenas, J. A., 2013) afirma que el filtro de Kalman es un algoritmo que se basa en el modelo de espacio de estados de un sistema para estimar el estado futuro realizando un filtrado óptimo, este filtro no requiere de una frecuencia de corte específica debido a que se enfoca en las características del ruido como tal permitiendo filtrar el espectro de frecuencias. El filtro de Kalman es esencialmente una serie de ecuaciones matemáticas que implementan un estimador tipo predictor – corrector que es óptimo en el sentido de minimizar el error estimado de la covarianza, cuando algunas condiciones son dadas.

(Weng et al., 2020) utilizó imágenes hiperespectrales para determinar la variedad de arroz utilizando una red de aprendizaje profundo por múltiples características, de 10 variedades de arroz de alta calidad en China. Para esto colocó 48 granos de arroz dispuestos en una matriz de 6 filas y 8 columnas, recolectando 90 imágenes para 10 tipos de arroz. Además, se analizó la textura mediante imágenes monocromáticas de longitudes de ondas que están altamente relacionadas con el arroz. Se realizó una corrección de la dispersión multivariante, se aplicaron la variante normal estándar, el suavizado de Savitzky-Golay y el primer orden para eliminar interferencia espectral, y se realizó un análisis de componentes principales (PCA) para obtener la información principal de las características de alta dimensión.

2.3.3 HERRAMIENTAS UTILIZADOS

En esta sección, se describirán las herramientas y enfoques que se utilizarán para analizar las variables financieras, primero iniciaremos con un análisis EDA de cada variable financiera, luego filtrar las series temporales financieras mediante el método de Savitzky-Golay y filtro por ajuste de Polinomios Locales DEI, análisis de residuos, después la descomposición de series de tiempo para comparar la eficiencia de los filtros y por último la implementación de métodos AR y ARIMA para evaluar las predicciones utilizando las variables sin filtro y con filtro .

Análisis Exploratoria de Datos (EDA): El análisis exploratorio de datos se realizará con el propósito de entender las características principales de las variables financieras seleccionadas y evaluar su comportamiento en relación con otras instituciones del sistema financiero. El objetivo del EDA es examinar patrones, identificar distribuciones y explorar posibles relaciones entre las variables seleccionadas para el estudio.

Filtro de Savitzky-Golay y filtro Ajuste Polinomial Local DEI: se evaluará la eficiencia de cada uno en el contexto de suavizado de series temporales. Al comparar estos filtros, se

analizará la capacidad de cada uno para mantener la fidelidad de los datos originales mientras reduce el ruido, así como su rendimiento en diferentes escenarios y tipos de datos, permitiendo así determinar la eficiencia relativa del filtro de Savitzky-Golay en comparación con el filtro por Ajuste Polinomial Local desarrollado por el DEI en la tarea de suavizado de series temporales.

Análisis de la Distribución de los Residuos: Se analizará la distribución de los residuos definidos como la diferencia entre la serie original y la serie filtrada, la distribución nos dará que también se está filtrando las serie con un grado de polinomio y una ventaja específica.

Descomposición de Series Temporales: Se realizará una descomposición de series temporales clásica con el método aditivo, para ver la tendencia, la estacionalidad y el ruido, se evaluará la varianza del ruido para determinar qué método de filtrado es mejor para suavizar las series y eliminar el ruido.

Predicciones con Método AR y ARIMA: Se realizará la metodología AR y ARIMA para hacer predicciones, estas predicciones serán en horizonte de 12 meses, para el entrenamiento de estos métodos usaremos toda la serie temporal menos los 12 meses que queremos proyectar que los usaremos como testeo de las predicciones de los modelos.

Prueba de Dickey-Fuller: Es una prueba que permite demostrar la existencia de estacionariedad, determinando la presencia de raíz unitaria en series de tiempo.

Gráfico ACF: El gráfico de autocorrelación proporciona los valores de autocorrelación de la serie con sus rezagos. En otras palabras, muestra la relación de valor presente de la serie con su valor pasado.

Gráfico PACF: El gráfico de autocorrelación parcial muestra la correlación de los residuos con el siguiente valor de retraso, por eso se le llama parcial y no completo ya que a medida que

elimina las variaciones encontradas antes de encontrar la siguiente correlación.

Uso de Técnicas de Visualización: Se emplearán gráficos y visualizaciones para identificar patrones, tendencias de las series temporales y sus diferentes filtros. Esto permitirá comprender mejor las diferencias entre las series temporales originales y sus filtros.

Uso de tablas: Se realizan tablas que contengan las diferentes métricas para evaluar el rendimiento de cada modelo de predicción, entre estas métricas están el MSE, RMSE, MAE, MAPE y la varianza para evaluar únicamente el uso del filtro para reducir el ruido.

2.4 MARCO LEGAL

La página de la (Comisión Nacional de Bancos y Seguros, 2024), menciona que:

La Central de Información Crediticia, es el sistema administrado por la Comisión Nacional de Bancos y Seguros (CNBS), mediante el cual se consolida la información proporcionada por las instituciones supervisadas de todas las personas naturales y jurídicas que adquieren compromisos u obligaciones crediticias con ellas, de su calidad de deudores, codeudores, avales o fiadores. (s.f.)

Este sistema está regido por las “Normas Para la Gestión de Información Crediticia”, aprobadas por la Resolución GES No.1047/11-06-2013. Estas normas han sufrido en algunos años algunas modificaciones y consideraciones, la última actualización fue realizada mediante la Resolución GRD No.185/29-03-2022, con el objetivo de promover la gestión de calidad en el manejo de la información referente a las operaciones crediticias de las instituciones supervisadas, determinar la responsabilidad de los diferentes estamentos internos en esta tarea y definir reglas para un funcionamiento adecuado de la Central de Información Crediticia (CIC) administrada por esta Comisión.

La Comisión establece los criterios mínimos sobre la administración de los sistemas de

información crediticia que promuevan el registro oportuno y exacto de las operaciones crediticias y la generación de información tanto para el uso interno y externo, en especial la generada con destino a la Central de Información Crediticia administrada por esta Comisión.

La Comisión Nacional de Bancos y Seguros (CNBS) no recopila la información directamente de los deudores, sino que la obtiene de las instituciones financieras supervisadas, que actúan como la fuente primaria de los datos. Estas instituciones son responsables de consolidar y remitir la información de las operaciones crediticias de sus clientes a la Central de Información Crediticia, asegurando que los registros sean precisos y oportunos.

2.4.1 MARCO LEGAL NACIONAL

En Honduras, el marco legal que rige la Central de Información Crediticia y los sistemas de información relacionados incluye, entre otras disposiciones:

- Ley de la Comisión Nacional de Bancos y Seguros (Decreto No.155-95), establece las funciones, atribuciones y responsabilidades de la CNBS, entre ellas, la supervisión de las instituciones financieras y la administración de la Central de Información Crediticia.
- Normas para la Gestión de Información Crediticia (Resolución GES No.1047/11-06-2013 y sus reformas), regulan los procedimientos para el registro, actualización y manejo de la información crediticia, asegurando la calidad, oportunidad y exactitud de los datos.
- Resolución GRD No.185/29-03-2022, es la última actualización que fortalece la administración y operatividad de la CIC.
- Ley de Protección al Consumidor (Decreto No.24-2008), protege los derechos de

los consumidores financieros, incluyendo el acceso a su información crediticia y la corrección de errores en sus registros.

2.4.2 MARCO LEGAL INTERNACIONAL

El marco legal internacional aplicable está relacionado con las mejores prácticas y principios adoptados globalmente para la gestión de información crediticia, incluyendo:

- (World Bank, 2011), menciona los Principios Generales para los Sistemas de Información Crediticia del Banco Mundial. Estos principios proporcionan lineamientos para el desarrollo de sistemas crediticios eficientes, transparentes y accesibles.
- (Basel Committee on Banking Supervision, 2012) define las Normas del Comité de Basilea para la Supervisión Bancaria donde se incluyen recomendaciones sobre la gestión del riesgo crediticio y la calidad de los datos que respaldan las decisiones financieras.
- (Reglamento (UE) 2016/679, 2016), establece el Reglamento General de Protección de Datos (GDPR, por sus siglas en inglés) específico de la Unión Europea, fija los estándares de referencia para la protección de datos personales, aplicables en la gestión de información crediticia.

CAPÍTULO III. METODOLOGÍA

El presente capítulo es un elemento importante para este proyecto de investigación, en él se describe el camino metodológico diseñado para el análisis de series temporales financieras, con un realce en la aplicación de técnicas avanzadas de filtrado y suavizado para series que presentan un alto nivel de ruido, la metodología seleccionada busca garantizar resultados precisos y confiables, que vayan alineados con los objetivos de esta investigación.

La metodología que se optó combina el uso del filtro de Savitzky-Golay y el filtro por Ajuste Polinomial Local, desarrollado por el Departamento de Estadísticas e Investigación (DEI), estas herramientas permitirán abordar de manera efectiva los desafíos al reducir el ruido en las series temporales financieras, preservando al mismo tiempo las características esenciales de los datos. La selección de estos métodos responde tanto en la base teórica sólida como en la capacidad de acoplarse a diferentes contextos financieros.

En este capítulo se detalla los procesos de implementación de los filtros mencionados, incluyendo los criterios y las estrategias para evaluar su desempeño. También, se describen las características de las series temporales analizadas, junto con los procesos de obtención que garanticen la integridad y calidad de los datos utilizados en el estudio.

3.1 CONGRUENCIA METODOLÓGICA

La tesis se enfoca en establecer un camino metodológico sólido para analizar las series temporales financieras con un enfoque específico en la utilización del filtro de Savitzky-Golay y el filtro por Ajuste Polinomial Local desarrollado por el DEI. La definición y elección de la metodología está en sintonía con los objetivos definidos, donde se abordará de manera sólida la tarea de filtrar o suavizar las series temporales financieras que exhiben un alto nivel de ruido.

3.2 MATRIZ METODOLÓGICA

La matriz metodológica constituye una herramienta clave en esta investigación, ya que permite organizar y estructurar las etapas del proceso de investigación de manera clara. Esta matriz establece una correspondencia directa entre los objetivos de la investigación y las preguntas planteadas, este enfoque garantiza que cada componente metodológico se establezca con el propósito general del estudio.

En este caso, la matriz metodológica se diseñó considerando el análisis de series temporales financieras mediante los filtros de Savitzky-Golay y el Ajuste Polinomial Local desarrollado por el DEI. Cada fila de la matriz revela los elementos necesarios para abordar el problema del ruido de las series temporales, incluyendo las variables seleccionadas para el estudio, los métodos de filtrado aplicados y las métricas de evaluación de los resultados, este esquema facilita el proceso y garantiza que los procedimientos sean coherentes con los objetivos específicos del estudio.

Tabla 1. Matriz Metodológica

Preguntas de Investigación	Objetivos	Hipótesis	Metodologías	Herramientas	VARIABLES
¿De qué manera la aplicación del filtro de Savitzky-Golay y del filtro desarrollado por el Departamento de Estadísticas e Investigación de la CNBS, en comparación con el análisis de las variables sin filtrar, mejora la precisión de las predicciones en series temporales financieras?	Evaluar el impacto del uso de los filtros para suavizar el ruido en las predicciones de modelos clásicos en series temporales financieras.	La presencia de ruido o alta volatilidad en series temporales financieras afecta negativamente las predicciones de los modelos AR y ARIMA.	Análisis de las métricas de los métodos AR y ARIMA para evaluar el impacto del ruido en las predicciones.	Software estadístico (por ejemplo, R, Python) para análisis de datos y modelado. Herramientas de visualización de series temporales. Bibliotecas específicas para modelos	VARIABLES que dependen del tiempo con componentes autorregresivas (indicador financiero a lo largo de una ventana de tiempo)
¿Cuál es la configuración	Determinar cuáles tipos de	Existe una ventana y un	Uso de una metodología		VARIABLES financieras

<p>¿Cuál es el impacto de la descomposición de una serie en la detección de anomalías en series temporales?</p>	<p>Evaluar cómo la descomposición de series temporales en sus componentes (tendencia, estacionalidad y residuos) mejora la capacidad de detectar anomalías en una variable temporal.</p>	<p>La descomposición de una serie temporal mejora la precisión y la efectividad en la detección de anomalías al permitir una identificación más clara de los componentes</p>	<p>Aplicar técnicas de descomposición de series temporales con la técnica de modelo aditivo o multiplicativo.</p>	<p>de predicción, series temporales y filtrado.</p>	<p>filtradas</p>
<p>¿Qué tan efectiva es la aplicación del filtro de Savitzky-Golay en comparación con el filtro desarrollado por el Departamento de Estadísticas e Investigación de la CNBS en la reducción de ruido sin pérdida de detalles críticos en la señal?</p>	<p>Determinar la capacidad de los filtros para suavizar las series de tiempo y la eliminación del ruido presente.</p>	<p>El filtro de Savitzky-Golay es mejor que el filtro desarrollado por el DEI.</p>	<p>Interpretación de todas las métricas para evaluar el rendimiento de las predicciones y de la disminución del ruido.</p>		<p>Variables financieras, predicciones, métricas de los modelos y la varianza para evaluar la disminución del ruido.</p>
<p>¿Cuál es el impacto de los filtros en términos de grado del polinomio y tamaño de ventana para el análisis de series temporales financieras?</p>	<p>ventanas y grados de polinomios son óptimos para ajustar los filtros.</p>	<p>grado del polinomio que permiten minimizar el error de ajuste y mejorar la precisión en la identificación de patrones y tendencias en señales ruidosas</p>	<p>para determinar el número de ventana y grado de polinomio óptimo.</p>		

Fuente: (Elaboración Propia, 2024)

3.3 ESQUEMA DE VARIABLES DE ESTUDIO

El estudio se enfoca en variables financieras representadas como series de tiempo con periodicidad mensual con un período de hasta casi 8 años que inicia de enero 2017 hasta septiembre 2024, obtenidas de la página de la CNBS en datos abiertos. Estas variables financieras abarcan cualquier cantidad o medida cuantificable utilizada para analizar, evaluar o gestionar aspectos relacionados con las finanzas de una empresa, entidad o individuo. Este estudio no se enfoca en la

tipología de la variable bajo un contexto financiero o económico, la única premisa crucial que estas variables deben cumplir es la de presentar una alta volatilidad y un ruido alto ya que el interés principal es analizar cómo estas variables financieras se ven impactadas e influenciadas a lo largo del tiempo, proporcionando así una comprensión más precisa de como su comportamiento y dinámicas subyacentes se ven afectadas.

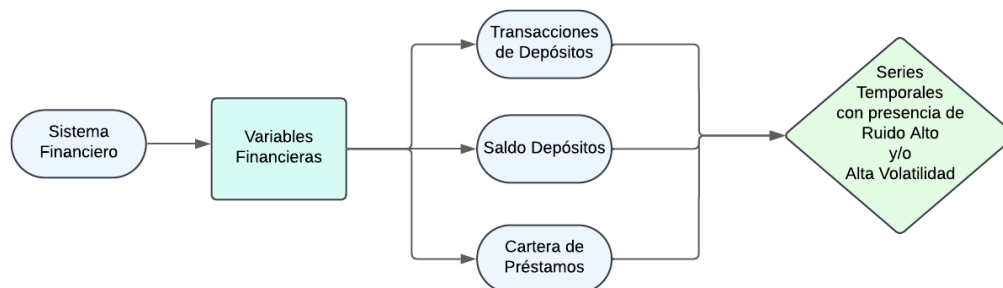


Figura 3: Esquema de las Variables de Estudio

Fuente: (Elaboración Propia, 2024)

3.3.1 DATOS ABIERTOS CNBS

La Comisión Nacional de Bancos y Seguros (CNBS) en su página web principal, ofrece un portal de Datos Abiertos, el cual se encuentra alineado con los principios de transparencia y acceso a la información pública. Este portal es parte de la iniciativa de Gobierno Abierto y tiene como objetivo facilitar el acceso a datos financieros y estadísticos relevantes, tanto para investigadores como para el público en general. Los datos disponibles abarcan información sobre el desempeño de las instituciones supervisadas, estadísticas del sistema financiero, indicadores económicos, y otra información relevante que contribuye al análisis y la toma de decisiones informadas.

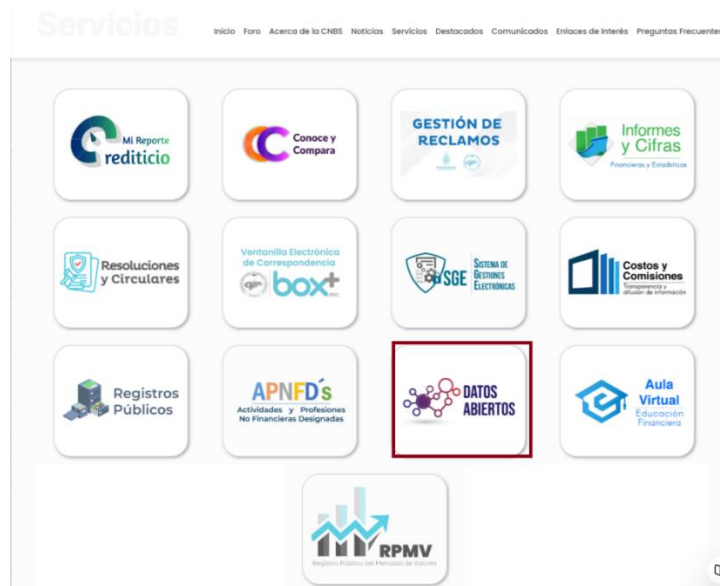


Figura 4: Portal de Datos Abiertos CNBS

Fuente: (Página Web, 2024)

Dentro del portal Datos Abiertos se encuentran 9 organizaciones que en la plataforma de CKAN son usadas para crear, gestionar y publicar colecciones de conjuntos de datos. Los datos que nos interesan se encuentran en la organización del Sistema Financiero ahí encontraremos los conjuntos de datos de los cuales extraemos las muestras para nuestro análisis.

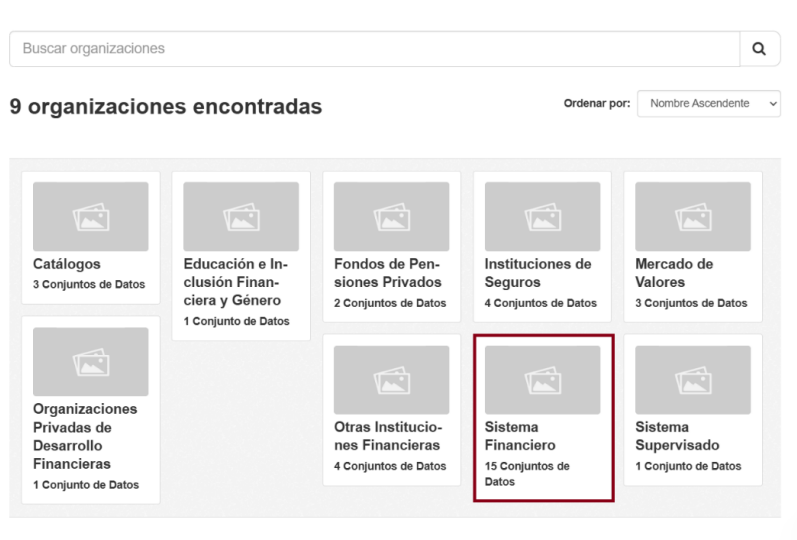


Figura 5: Organizaciones en Datos Abiertos CNBS

Fuente: (Página Web, 2024)

3.4 OPERACIONALIZACIÓN DE LAS VARIABLES

La operacionalización de las variables financieras implica definir y medir de manera precisa las características de estudio en esta investigación ya que, en el contexto de las series temporales financieras con alta volatilidad y ruido, la operacionalización de las variables financieras deberá incluir los siguientes aspectos.

Definición de Variables: Identificar las variables financieras de interés, como saldos de cuentas bancarias, tasas de interés, etc.

Medición de Variables: Establecer la unidad de medida para cada variable ya sea en dólares o lempiras para saldos de cuentas bancarias y porcentaje para tasas de interés. Así mismo, determinar la periodicidad de la medición (mensual, trimestral, anual) según la disponibilidad de datos.

Captura de Volatilidad y Ruido: Utilizar medidas estadísticas como la desviación estándar, el coeficiente de variación o la amplitud para capturar la volatilidad de las variables financieras. Aplicar técnicas de suavizado o filtrado y descomposición de series para reducir el ruido y hacer más evidentes las tendencias subyacentes.

Segmentación de Datos: Dividir los datos en períodos específicos (por ejemplo, trimestres o años) para analizar cambios y patrones a lo largo del tiempo.

Análisis de Tendencias y Patrones: Emplear métodos como el análisis de series temporales, gráficos de tendencia y análisis de ciclo para identificar patrones estacionales, tendencias y comportamientos irregulares.

Validación y Consistencia: Verificar la consistencia y la validez de los datos recopilados.

Tabla 2. Matriz de Procesos

Etapa	Actividades	Herramientas/Métodos
Preparación y recopilación de los datos	Recopilación de los datos financieros de periodicidad mensual.	Los datos se obtuvieron de los conjuntos de datos abiertos que mantiene al público la CNBS
	Verificación de la calidad, consistencia e integridad de los datos.	La CNBS tiene un departamento que verifica la calidad, consistencia e integridad de la información.
Análisis EDA de las variables financieras	Análisis exploratorio de las variables financieras para ver su distribución, tendencias en un mes específico.	Gráficos de barras, gráficos de líneas, gráficos circulares.
Ajustes e implementación de	Implementación de las metodologías de	Métodos estadísticos matemáticos

los filtros propuestos	filtrados de las series temporales financieras.	usados para filtrar las series temporales.
	Ajustes de los parámetros del filtrado o suavizado de las series temporales financieras.	Técnicas de ajustes de los parámetros Programar el algoritmo de la implementación de los modelos de filtrado
Implementación de la descomposición de las series temporales	Descomponer las series temporales de cada variable en sus componentes de tendencia, estacionalidad y ruido.	Programar el algoritmo de la implementación de la descomposición de series temporales.
Análisis predictivos con metodologías AR y ARIMA	Realizar los análisis predictivos con las series filtradas y originales para comparación.	Programar el algoritmo de entrenamiento y testeo de las predicciones de cada variable
Validación y evaluación de los resultados	Evaluar qué metodología de filtrado tiene las mejoras métricas al implementar los filtros y evaluar el rendimiento de las series filtradas con sus proyecciones.	Interpretación de las métricas para evaluar el rendimiento de los filtros y las proyecciones de cada variable
Conclusiones y recomendaciones	Detallar las conclusiones y recomendaciones derivadas del análisis de resultados	Responder a las preguntas de investigación, incluyendo las hipótesis planteadas.

Fuente: (Elaboración Propia, 2024)

3.5 HIPÓTESIS

En el contexto de la investigación y análisis de las series temporales financieras, es importante formular las hipótesis porque guían el estudio y la interpretación de los resultados, es por eso nos hemos planteado algunas hipótesis tales como:

Al evaluar el impacto del ruido en las predicciones de modelos clásicos nos planteamos

- **Hipótesis nula (H0):** La presencia de ruido o alta volatilidad en series temporales financieras no afectan negativamente las predicciones de los modelos AR y ARIMA.
- **Hipótesis alternativa (H1):** La presencia de ruido o alta volatilidad en series temporales financieras afectan negativamente las predicciones de los modelos AR y ARIMA, disminuyendo su precisión y exactitud.

Al determinar cuáles son los tipos de ventanas y grados de polinomios para ajustar los filtros, planteamos lo siguiente.

- **Hipótesis nula (H0):** No existe una ventana y un grado del polinomio que permiten minimizar el error de ajuste y mejorar la precisión en la identificación de patrones y tendencias en señales ruidosas.
- **Hipótesis alternativa (H1):** Existe una ventana y un grado del polinomio que permiten minimizar el error de ajuste y mejorar la precisión en la identificación de patrones y tendencias en señales ruidosas.

Al analizar la capacidad de los filtros planteados en este estudio para suavizar las series temporales para eliminar el ruido presente, nos planteamos lo siguiente.

- **Hipótesis nula (H0):** El filtro de Savitzky-Golay es mejor que el filtro desarrollado por el DEI en la reducción de ruido sin pérdida de tendencias adyacentes.
- **Hipótesis alternativa (H1):** El filtro de Savitzky-Golay no es mejor que el filtro desarrollado por el DEI en la reducción de ruido sin pérdida de tendencias adyacentes.

Por último, al analizar el impacto de la descomposición de series temporales en la detección de anomalías, nos planteamos lo siguiente.

- **Hipótesis nula (H0):** La descomposición de una serie temporal no mejora la precisión y la efectividad en la detección de anomalías.
- **Hipótesis alternativa (H1):** La descomposición de una serie temporal mejora la precisión y la efectividad en la detección de anomalías al permitir una identificación más clara de los componentes.

3.6 ENFOQUE Y MÉTODOS

3.6.1 ENFOQUE

El enfoque de esta investigación será de tipo cuantitativo ya que busca comprender el impacto del ruido y la alta volatilidad presente en las series temporales financieras y cómo esto afecta las predicciones. La comprensión del impacto del ruido, la alta volatilidad y la mejora en las predicciones se abordarán mediante el uso de los filtros de Savitzky-Golay y el desarrollado

por el DEI.

3.6.2 ALCANCE

El alcance de esta investigación es de tipo correlacional – explicativo, experimental y longitudinal. Experimental, porque se analiza cómo el uso de dos filtros para suavizar series temporales (Savitzky-Golay y el desarrollado por el DEI) impacta en las predicciones realizadas con los modelos AR y ARIMA. Longitudinal, porque el análisis abarca un periodo de tiempo extendido, permitiendo observar cómo el comportamiento de las series temporales y las predicciones evolucionan a lo largo del tiempo, antes y después de aplicar los filtros. Correlacional y explicativo, porque además de evaluar la relación, se busca identificar qué filtro reduce mejor el ruido o volatilidad de las series temporales y como el filtro mejora o afecta las características de las series y su impacto en las predicciones.

3.6.3 DISEÑO

De acuerdo con su naturaleza la investigación se alinea con un diseño experimental porque se manipulan variables con la aplicación de los filtros de Savitzky-Golay y el desarrollado por el DEI y se evalúan el impacto que tienen sobre las predicciones. Así mismo, es no experimental longitudinal ya que se recolectan datos en diferentes momentos o periodos para hacer inferencias respecto al cambio, sus determinantes y consecuencias.

3.7 DISEÑO DE LA INVESTIGACIÓN

En este capítulo, se detalla el diseño metodológico, el diseño investigación está estructurado de manera sistemática y coherente, con el propósito de alcanzar los objetivos planteados y responder a las preguntas de investigación de manera efectiva.

3.7.1 POBLACIÓN

La población de estudio estará constituida por datos financieros históricos disponibles públicamente, obtenidos únicamente de la CNBS (Comisión Nacional de Bancos y Seguros, 2024).

Incluye todas las variables financieras reportadas por las instituciones supervisadas, lo que proporciona un marco amplio y diverso para el análisis. La población considerada en este estudio está conformada por la estructura del Sistema Financiero, que abarca 15 conjuntos de datos principales. Cada uno de estos conjuntos incluye múltiples subconjuntos o recursos específicos, los cuales se detallan a continuación:

1. Préstamos Vigentes y Nuevos por Destino.

- Préstamos
- Préstamos a Detalle
- Préstamos (Desde enero 2024)
- Préstamos Detalle (Desde enero 2024)

2. Indicadores.

- Indicadores (hasta diciembre 2016)
- Indicadores (desde enero 2017)
- Indicadores (desde enero 2024)

3. Boletín de Datos de la Central de Información Crediticia.

- Cartera Total por Género
- Deudores por Institución Género
- Deudores por Tipo Crédito Género
- Cartera Total por Categoría
- Cartera Total CIC
- Cartera Total por Categoría
- Cartera Total por Categoría Moneda

4. Estados Financieros.

- Balance General Prudencial
- Estado de Resultado Prudencial

- Balance General
 - Estado Resultado
5. Tasas por Destino de Fondos BCH.
- Tasas BCH
6. Tasas de Interés Máximas y Mínimas aplicadas en el mes.
- Tasas
7. Ranking.
- Ranking
8. Transacciones Financieras en Cuentas de Depósitos por Institución.
- Transacciones depósitos
9. Tarjetas de Débito en el Mercado por Institución.
- Tarjetas de Débito en Circulación
10. Comportamiento de Tarjetas.
- Comportamiento TC
 - Comportamiento TC (en base a balance)
11. Depósitos a Término.
- Depósitos por Escala
 - Depósitos por Institución
 - Depósitos por Distribución Geográfica
12. Tarjetas de crédito en el Mercado.
- Tarjetas Mercado
 - Tarjetas Monto Otorgado
13. Depósitos de Ahorro.
- Depósitos por Institución

- Depósitos por Escala
- Depósitos por Distribución Geográfica

14. Depósitos a la Vista.

- Depósitos por Institución
- Depósitos por Escala
- Depósitos por Distribución Geográfica

15. Tasas Pactadas/ Depósitos a Término por Vencimiento y Monto.

- Tasas Pactadas entre Depósitos a Término
- Tasas Pactadas entre Depósitos a Término al Mes

Estos conjuntos contienen variables que presentan una naturaleza dinámica, ya que su actualización se realiza con periodicidad mensual o trimestral, dependiendo de su tipología. Esto implica que el número total de variables dentro de la población no es constante ni fácilmente determinable, dado que cada conjunto de datos varía en tamaño y composición según el período de análisis. La heterogeneidad en la periodicidad y en el volumen de información de cada conjunto añade complejidad al proceso de definición y delimitación exacta de la población estudiada, ya que las actualizaciones periódicas generan cambios constantes en su estructura y contenido.

3.7.2 MUESTRA

Dado el extenso conjunto de variables financieras y su histórico registrado por la CNBS (Comisión Nacional de Bancos y Seguros, 2024), se seleccionó una muestra no probabilística altamente representativa de las variables con mayor volatilidad y ruido dentro de los datos financieros. Esta elección no se basó en la tipología de las variables ni en su contexto financiero o económico, sino que estuvo alineada con los objetivos del estudio centrándose únicamente en analizar variables financieras que presentan altos niveles de ruido y volatilidad, permitiendo responder con precisión y eficiencia a las hipótesis y preguntas planteadas en la investigación, garantizando que los hallazgos sean relevantes y precisos.

Tras un análisis exploratorio de las variables, se identificó que la muestra, compuesta por variables que cumplen con los criterios de alto ruido y volatilidad, abarca tres subconjuntos de los 15 conjuntos de datos principales, los cuales se describen a continuación:

1. Boletín de Datos de la Central de Información Crediticia.
 - Cartera Total CIC
2. Depósitos de Ahorro.
 - Depósitos por Institución
3. Transacciones Financieras en Cuentas de Depósitos por Institución.
 - Transacciones depósitos

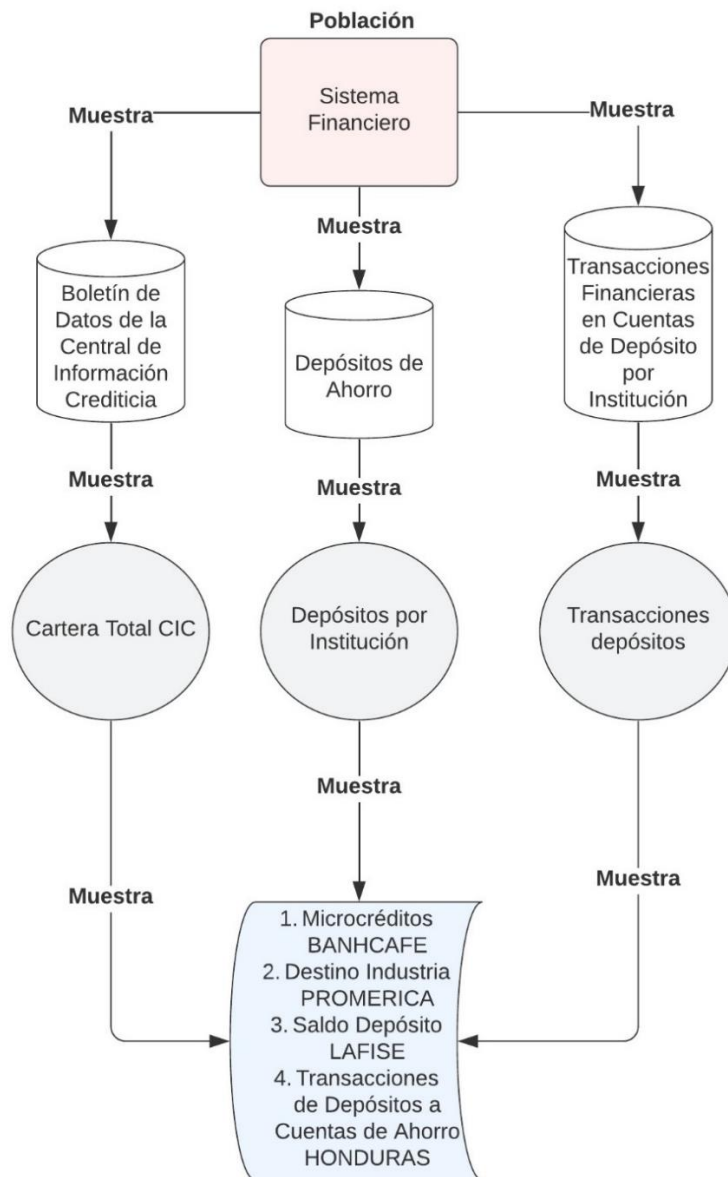


Figura 6. Proceso de Selección de la Muestra para el Estudio de Variables Financieras

Fuente: (Elaboración Propia, 2024)

3.7.3 TÉCNICAS DE MUESTREO

La muestra será seleccionada mediante un Muestreo a Conveniencia con el objetivo de abarcar diferentes períodos de tiempo y tipos de datos financieros relevantes, y limitar que la muestra contenga series temporales financieras que exhiben una alta volatilidad y ruido significativo.

3.8 TÉCNICAS, HERRAMIENTAS Y PROCEDIMIENTOS APLICADOS

Para abordar el análisis de series temporales financieras y la evaluación de los efectos del ruido alto, la detección de anomalías y la eficacia de los métodos del filtrado se implementará una serie de técnicas, herramientas específicas y procedimientos adecuados para alcanzar los objetivos planteados, dentro de las principales técnicas, herramientas y procedimientos.

3.8.1 TÉCNICAS

Recopilación de datos:

Los datos utilizados en este estudio fueron obtenidos del apartado de datos abiertos en la página web de la Comisión Nacional de Bancos y Seguros (CNBS) y descargados en formato CSV. Posteriormente, se llevó a cabo un proceso de depuración y selección de la muestra, asegurando que ésta cumpliera con las características de alto nivel de ruido y volatilidad. Este procedimiento tuvo como propósito garantizar que los datos sean adecuados para mejorar la precisión y la representatividad de los modelos desarrollados.

Análisis Exploratorio de Datos (EDA):

Se llevará a cabo un análisis descriptivo para explorar las características principales de las series temporales financieras. El propósito central del EDA (Análisis Exploratorio de Datos) es comprender la posición y el comportamiento de cada institución financiera involucrada, con énfasis en las variables seleccionadas para el estudio.

Descomposición de series temporales:

Se realizará la descomposición de series temporales, es una técnica que permite dividir una serie en sus componentes fundamentales, lo cual facilita la comprensión y análisis del comportamiento subyacente.

Análisis predictivo:

Se realizaron análisis predictivos utilizando modelos clásicos como AR y ARIMA, así mismo, se aplicarán modelos de suavizado o filtrado como el de Savitzky-Golay y el desarrollado por el DEI para pronosticar valores futuros y evaluar la precisión de las predicciones.

Análisis Comparativo:

Se llevará a cabo un análisis comparativo para comparar el desempeño de diferentes métodos de filtrado en términos de reducción de errores y mejora de la precisión en las predicciones con las métricas de cada modelo.

3.8.2 HERRAMIENTAS

Para la extracción de las variables, aplicación de los filtros y entrenamientos de los modelos predictivos AR y ARIMA, se utilizaron herramientas claves en este proceso:

Aplicación de Excel: Este instrumento fue empleado para la depuración de datos, la selección de variables que conformaron la muestra del estudio y la realización del Análisis Exploratorio de Datos (EDA). Además, se utilizó para generar gráficos que ilustran las características principales de las variables y para elaborar tablas que presentan las métricas utilizadas en la evaluación de los modelos.

Entorno Jupyter Notebook: El entorno Jupyter Notebook será una herramienta clave utilizada a lo largo de esta investigación. Jupyter es un entorno interactivo que permite ejecutar código Python de manera eficiente y flexible, facilitando la integración de múltiples procesos analíticos en un solo espacio de trabajo.

Entre las funcionalidades principales de Jupyter Notebook destaca su compatibilidad con librerías especializadas como Pandas, NumPy, Statsmodels, SciPy y Scikit-Learn. Estas herramientas serán esenciales para llevar a cabo tareas críticas, como el análisis y procesamiento

de datos, la aplicación de los filtros propuestos, y la descomposición de las series temporales.

Adicionalmente, Jupyter permitirá entrenar los modelos predictivos AR y ARIMA con precisión, evaluando su desempeño en el mejoramiento de las predicciones.

3.8.3 PROCEDIMIENTOS APLICADOS

Esta sección detalla los métodos implementados en el análisis de las series temporales financieras, abarcando la aplicación de filtros, la descomposición de las series y el uso de modelos de predicción.

3.8.4 FILTROS APLICADOS

Para suavizar y reducir el ruido presente en las series temporales, se emplearon filtros, como el filtro de Savitzky-Golay y el filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI). Ambos fueron aplicados con el propósito de mejorar la calidad de las series y facilitar la identificación de patrones subyacentes.

3.8.5 DESCOMPOSICIÓN DE SERIES DE TIEMPO

Se realizó la descomposición de las series temporales en sus componentes principales: tendencia, estacionalidad y ruido. Este procedimiento permitió analizar cada componente por separado, proporcionando una comprensión más clara de los factores que afectan el comportamiento de las series.

3.8.6 MODELOS DE PREDICCIÓN

En esta etapa se implementaron y evaluaron modelos AR (Autoregresivo) y ARIMA, seleccionados por su capacidad para capturar la dinámica temporal y realizar predicciones basadas en los datos históricos. Estos modelos fueron entrenados y validados utilizando métricas para medir su precisión y eficacia de cada uno de los filtros en la reducción del ruido.

3.9 FUENTES DE INFORMACIÓN

Las fuentes de información proporcionan datos directos y actualizados que son fundamentales para llevar a cabo un análisis riguroso y obtener conclusiones sólidas en el estudio de series temporales financieras.

3.9.1 FUENTES SECUNDARIAS

De acuerdo con la Ley de la Central de Información Crediticia, todas las instituciones financieras están obligadas a reportar la información requerida por la Comisión Nacional de Bancos y Seguros (CNBS). Esta normativa garantiza la disponibilidad de datos actualizados y precisos sobre las operaciones financieras realizadas en el país.

La CNBS recopila y verifica exhaustivamente los datos reportados por las instituciones financieras supervisadas. Una vez finalizado este proceso, el equipo de tecnología de la CNBS genera conjuntos de datos organizados que se ponen a disposición pública a través del apartado de Datos Abiertos en la página web oficial de la institución (Comisión Nacional de Bancos y Seguros, 2024).

Esta práctica se sustenta en la reputación y autoridad de la CNBS como ente regulador del sistema financiero, garantizando que los datos sean confiables, actualizados y relevantes para el análisis de series temporales financieras. Además, al publicar estos datos en un formato accesible, se promueve la transparencia y se fomenta la posibilidad de replicar y validar los resultados de investigaciones, fortaleciendo el rigor y la credibilidad en el sector financiero.

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

El análisis de los datos recopilados y la presentación de los resultados, representan una fase primordial en la investigación, ya que permite la revelación de las relaciones y efectos de las variables en estudio, proporcionando una base empírica que sustente las conclusiones del estudio. Esto fortalece la credibilidad y relevancia de la investigación, permitiendo que los hallazgos puedan ser utilizados para formular nuevas teorías y contribuir al desarrollo de conocimientos en el área.

En este capítulo se presentan los hallazgos derivados del análisis de datos recopilados, con el objetivo de responder a las preguntas de investigación planteadas y de validar o refutar las hipótesis formuladas en el estudio. Los resultados obtenidos representan una traducción directa de los datos, permitiendo una comprensión más profunda de la problemática abordada.

En particular, este análisis es fundamental para comparar la efectividad del filtro de Savitzky-Golay con el filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI) de la CNBS, ambos aplicados a variables con altos niveles de ruido. A través de estos análisis se busca identificar cuál de los dos métodos de filtrado es más efectivo en la reducción del ruido sin pérdida de información relevante y se evalúa cómo cada filtro impacta en la precisión de las predicciones, lo cual resulta esencial para validar la utilidad de los datos en aplicaciones analíticas y predictivas.

4.1 INFORME DE PROCESO DE RECOLECCIÓN DE DATOS

El proceso de recolección de datos se realizó a través de la página web de la Comisión Nacional de Bancos y Seguros (CNBS), específicamente en el apartado de datos abiertos en CKAN. Según la página web de la CNBS, “esta plataforma hace que los datos sean accesibles y utilizables al proveer herramientas para publicar, compartir, encontrar y usar los datos (incluyendo

almacenamiento de datos y provisión de APIs de datos robustas). CKAN está orientada a proveedores de datos (gobiernos nacionales y regionales, compañías y organizaciones) que desean hacer sus datos abiertos y disponibles” (*Acerca De - Datos Abiertos*, 2024).

La idea de utilizar datos de código abierto es para garantizar que la fuente esté disponible y la transparencia de los datos, asegurando que la información utilizada sea confiable y actualizada. En la plataforma CRAI de la CNBS existen diversos conjuntos de datos, que van desde estados financieros, indicadores, detalles de préstamos, tasas de interés, transacciones de depósitos, comportamiento de tarjetas de crédito y número de tarjetas en el mercado, etc.

La información presentada por la CNBS es recopilada a través de capturadores de datos, donde las instituciones supervisadas cargan la información según la periodicidad establecida por el ente regulador. Este proceso de carga es fundamental, ya que garantiza que los datos se obtengan de manera sistemática y en los plazos requeridos, una vez recopilados, los datos pasan por una serie de filtros diseñados para validar su precisión, consistencia y completitud, así como para asegurar que estén actualizados. Es importante destacar que, en ningún momento, la CNBS modifica o altera los datos reportados por las instituciones, garantizando la integridad y la fiabilidad de la información, permitiendo que los análisis posteriores se basen en datos auténticos y verificables.

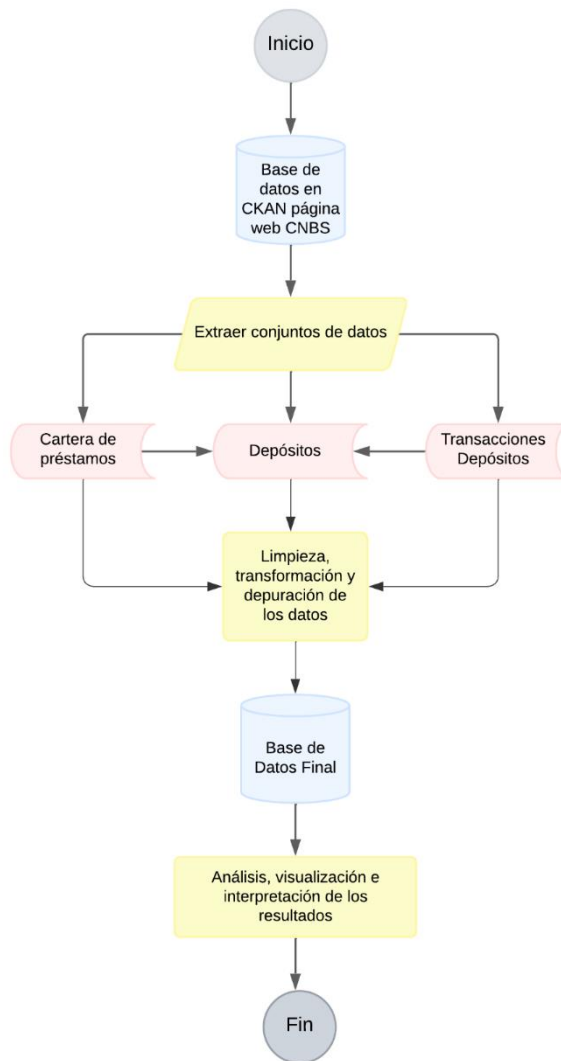


Figura 7. Diagrama de Recolección, Limpieza, Transformación y Depuración de Datos

Fuente: (Elaboración Propia, 2024)

4.2 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS

4.2.1 ANÁLISIS EXPLORATORIO DE DATOS (EDA)

Primero, realizamos un Análisis Exploratorio de Datos (EDA) de las variables seleccionadas de la población, que incluyen cartera, depósitos y transacciones de depósitos. Para asegurar la consistencia del análisis, consideramos únicamente el sector de Bancos Comerciales dentro de las instituciones supervisadas, conformado por 15 bancos. Este análisis busca entender

las diferencias en el comportamiento de las variables entre los bancos del sector, con el objetivo de detectar heterogeneidades que puedan ser indicativas de particularidades operativas, estrategias comerciales o niveles de exposición al riesgo en cada institución.

4.2.1.1 ANÁLISIS EDA DE LA CARTERA DE PRÉSTAMOS DE MICROCRÉDITO

Los bancos como POPULAR, BANPAIS, BANHCAFE y AZTECA, con cifras al cierre del mes de septiembre 2024, son las únicas instituciones que mantienen una cartera de microcréditos. El análisis EDA muestra que el banco con mayor saldo de cartera de microcréditos es el banco POPULAR con L.1,911 millones, seguidos por BANRURAL con L.733 millones, BANPAIS con un monto de L.206 millones, BANHCAFE con L.131 millones y por último AZTECA con solo L.2 millones.

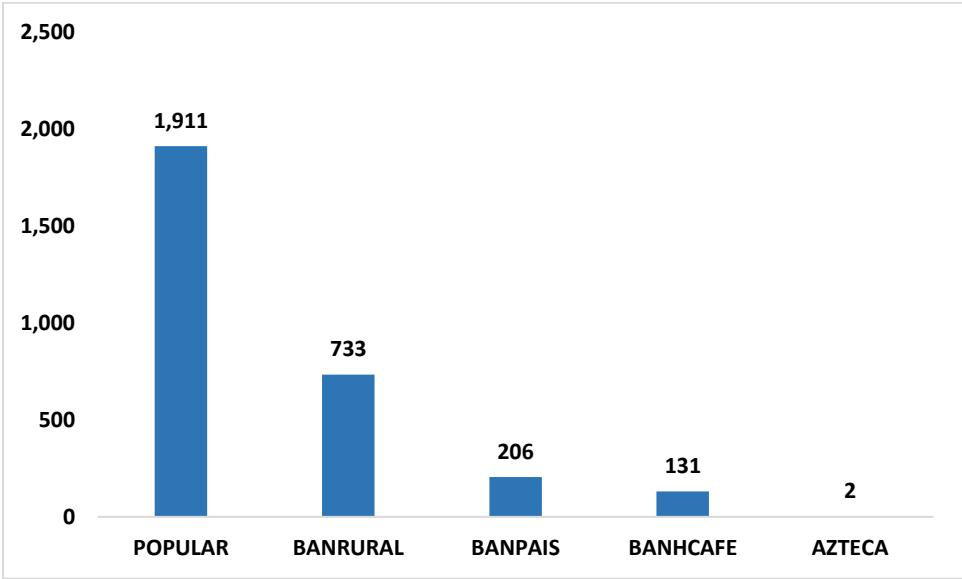


Figura 8. Saldos de Cartera de Microcréditos por Banco

Fuente: (Elaboración Propia, 2024)

4.2.1.2 ANÁLISIS EDA DE LA CARTERA DE PRÉSTAMOS, DESTINO INDUSTRIA

Al cierre de septiembre 2024, la cartera de préstamos con destino a la Industria, que

FICOHSA lidera con un valor superior de L.15,449 millones, seguido de BANCATLAN con L.6,257 millones, y BAC CREDOMATIC con L.4,065 millones, seguidos de BANCOCCI y BANPAIS que registran L3,531 millones y L.3,018 millones, respectivamente, mientras que DAVIVIENDA alcanza los L.1,978 millones. Las cifras de los demás bancos son considerablemente menores, como BANRURAL con L.711 millones, y varios, incluyendo PROMERICA y CUSCATLÁN, con valores inferiores a L200 millones.




Figura 9. Saldos de Cartera de Destino Industria por Banco

Fuente: (Elaboración Propia, 2024)

4.2.1.3 ANÁLISIS EDA DEL SALDO EN DEPÓSITOS

Al cierre de agosto 2024, con mayor saldo de depósito lo lidera BANCOCCI con un saldo de L.80,298 millones, seguido por BANCATLAN con un saldo de L.53,913 millones y BAC CREDOMATIC con un saldo de L. 40,876 millones. FICOHSA y BANPAIS también tienen saldos significativos, con L.35,904 millones y un L.28,557 millones, respectivamente, mientras que DAVIVIENDA alcanza un saldo de L.15,963. Los bancos restantes tienen saldos de depósitos mucho menores, como LAFISE con L.5,711 millones y BANRURAL con L.4,665 millones.

Instituciones como AZTECA, POPULAR y HONDURAS mantienen un saldo menor de L.2,000 millones en depósitos.




Figura 10. Participación de los Depósitos por Banco

Fuente: (Elaboración Propia, 2024)

4.2.1.4 ANÁLISIS EDA DE TRANSACCIONES DE DEPÓSITOS A CUENTAS DE AHORRO

Al cierre de agosto 2024, se presenta el número de transacciones de depósitos a cuentas de ahorro de distintos bancos siendo BAC CREDOMATIC el líder con 16,198 mil transacciones, seguido por BANPAIS con 10,352 mil y BANCOCCI con 9,774 mil. FICOHSA y BANCATLAN también registran cifras importantes, con 7,749 mil y 5,561 mil transacciones, respectivamente. Los demás bancos tienen volúmenes significativamente menores, como DAVIVIENDA con 1,351 mil y CUSCATLÁN con 1,314 mil, mientras que instituciones como BANRURAL y HONDURAS tienen menos de 100 mil transacciones.

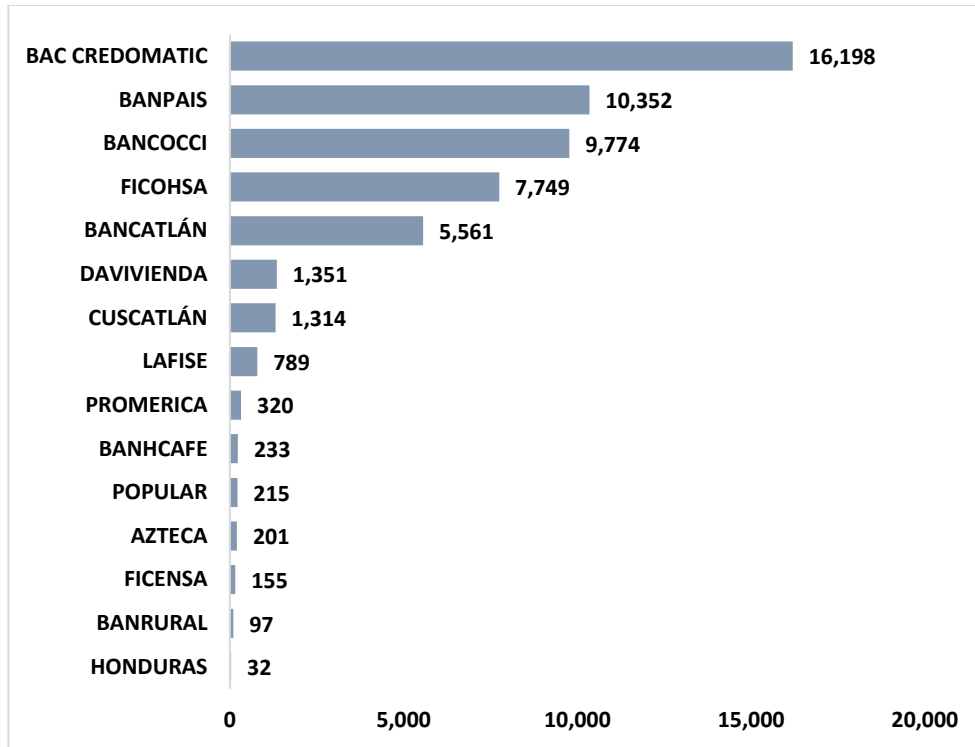


Figura 11. Número de Transacciones de Depósitos a Cuentas de Ahorro por Banco

Fuente: (Elaboración Propia, 2024)

4.3 ANÁLISIS DE LA METODOLOGÍA APLICADA

En esta sección, se presentan los resultados obtenidos al analizar cada uno de los componentes del filtrado, el análisis de los residuos, la descomposición de series temporales y, por último, la aplicación de los métodos AR y ARIMA para realizar proyecciones sobre las series filtradas de las variables financieras seleccionadas en la muestra. Antes de iniciar el análisis, es fundamental determinar de manera general el tamaño de la ventana y el grado del polinomio que se emplearán para ajustar los parámetros de los filtros, así mismo, se establecerán algunos criterios para el método AR y ARIMA. Esto nos permitirá implementar una metodología uniforme para cada variable y, así, comparar los resultados obtenidos bajo un mismo contexto de ajuste.

(Dombi y Dineva, 2020) explican que el tamaño de la ventana para el filtro Savitzky-Golay se define como $M = 2m + 1$ donde m es la mitad del tamaño de la ventana. La selección del

tamaño de la ventana (M) y el grado del polinomio (k) en el filtro Savitzky-Golay debe adaptarse a la escala y las características frecuenciales de la señal a analizar.

En relación con lo anterior, y tomando en cuenta el análisis frecuencial de las series temporales, se ha determinado el tamaño de la ventana y el grado del polinomio de la siguiente manera:

- Se desea realizar una proyección de 12 meses por lo cual es necesario elegir un tamaño de ventana que cubra hasta 12 meses, lo que permitirá identificar tendencias anuales sin perder la variabilidad mensual, según la fórmula $m = 6$ es la mitad del tamaño de la ventana, por tanto, usaremos un tamaño de ventana de $M = 13$ meses.
- El grado del polinomio (k) dependerá del nivel de suavización deseado y de la flexibilidad requerida para ajustar las fluctuaciones dentro de cada ventana. Un grado de polinomio más alto permite un ajuste más flexible, pero también aumenta el riesgo de sobreajuste. Estudios sobre el “Filtrado adaptativo Savitzky-Golay y sus aplicaciones” sugieren que para una ventana mayor a $M \geq 11$ se use un grado de polinomio de $k = 5$ (Dombi y Dineva, 2020).

Para el caso del método AR (Auto Regresivo) se consideró usar 12 valores anteriores de la serie para hacer las predicciones, se hizo este ajuste ya se realizarán predicciones con una ventana de 12 meses hacia adelante. Por último, en el caso de la metodología ARIMA (Modelo Autorregresivo Integrado de Media Móvil), se realizó para cada variable una prueba de Dickey-Fuller para determinar si la serie es estacionaria, para las series que no eran estacionarias se les aplicó una primera y/o segunda diferencia, dependiendo la particularidad de cada una de la serie, al aplicar la prueba se observó que las series de cada variable son estacionarias con su segunda

diferencia. Aunado a lo anterior, se realizó un análisis de series temporales que utiliza la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF). Estas funciones las interpretamos en forma de gráficos para identificar los parámetros de los componentes autorregresivos (AR) y de promedio móvil (MA) en los modelos ARIMA.

En general, para los métodos AR y ARIMA se dividió la serie de tiempo en dos conjuntos de datos; data de entrenamiento y data de testeo. Esta división se realizó con el objetivo de poder verificar la eficacia de cada modelo testeando los datos proyectados con los datos originales para cada metodología.

4.3.1 ANÁLISIS DE LA CARTERA DE PRÉSTAMOS DE MICROCRÉDITO DE BANHCAFE

Para esta sección se analizará la cartera de préstamos de microcrédito del banco BANHCAFE siguiendo la metodología propuesta anteriormente.

4.3.1.1 FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE BANHCAFE

Al aplicar el filtro de Savitzky-Golay (Figura 12) y el filtro de ajuste DEI (Figura 14) a la serie de tiempo de los préstamos de microcrédito de BANHCAFE, se pueden observar diferencias significativas entre ambos enfoques. En ambos gráficos, la línea azul representa la serie original, mientras que la línea roja punteada indica la serie filtrada, así mismo, se muestra las distribuciones de los residuos de ambos filtros (Figura 13 y Figura 15).

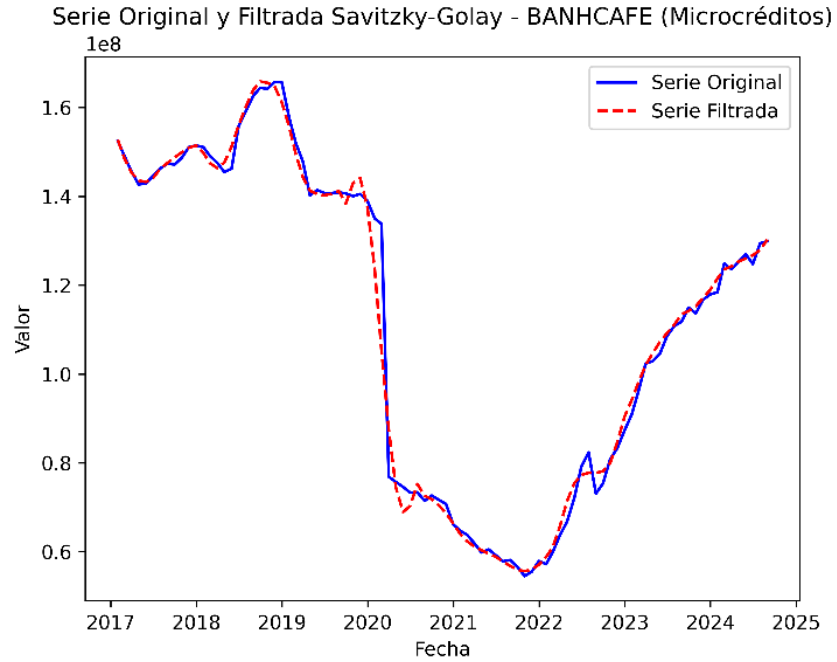


Figura 12. Aplicación del filtro de Savitzky-Golay a la Serie de Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)




Figura 13. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)

El filtro de Savitzky-Golay sigue de manera más ajustada las fluctuaciones de la serie original, capturando picos y cambios bruscos con mayor fidelidad. En cambio, el filtro DEI tiende a suavizar más los picos y valores extremos, lo que resulta en una serie más estable y menos volátil. Al analizar la distribución de los residuos (diferencia entre la serie original y la filtrada), se observa que, para el filtro de Savitzky-Golay, la curva de densidad empírica (azul) está más ajustada a la normal teórica (roja). Por su parte, los residuos del filtro DEI presentan una mayor variabilidad, lo que sugiere que este filtro podría estar realizando una suavización más agresiva, afectando algunas características de la serie original.




Figura 14. Aplicación del filtro DEI a la Serie de Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)




Figura 15. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Microcréditos BANHCAFE

En general, el filtro desarrollado por el DEI parece disminuir mejor el ruido presente en la serie original, lo que sugiere que es más efectivo para suavizar la serie. Sin embargo, esta suavización podría venir a costa de perder detalles importantes de las fluctuaciones, lo que indica un posible compromiso entre la eliminación del ruido y la preservación de la información subyacente.

4.3.1.2 DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA LA SERIE DE BANHCAFE

Al aplicar la descomposición de series de tiempo a la variable de préstamos de BANHCAFE (Microcréditos) sin filtro, con filtro de Savitzky-Golay y el filtro desarrollado por el DEI se obtuvieron los siguientes resultados que se muestran en la siguiente figura.




Figura 16. Descomposición de Serie Temporal: Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)




Figura 17. Descomposición de Serie Temporal: Filtro Savitzky-Golay Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)




Figura 18. Descomposición de Serie Temporal: Filtro DEI Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)

La descomposición de la serie de microcréditos de BANHCAFE utilizando el filtro Savitzky-Golay (SG) y el filtro desarrollado por el DEI presenta en la serie original una tendencia decreciente hasta 2021, seguida de una recuperación gradual, el filtro SG permite una suavización más sutil, captando los cambios y fluctuaciones de manera cercana a la serie original, mientras que el filtro DEI produce una tendencia más uniforme y suaviza los picos de forma notable. Ambos filtros mantienen patrones estacionales similares, pero el filtro DEI reduce significativamente los residuos, lo que sugiere una mayor efectividad en la eliminación del ruido, aunque podría sacrificar algunos detalles de las fluctuaciones originales.

Tabla 3. Análisis de Varianza de los Residuos para la Serie de Microcréditos de BANHCAFE

Serie BANHCAFE Microcréditos	Varianza de los Residuos
Original	44,328
Filtro Savitzky-Golay	32,073
Filtro DEI	10,457

Escala de las cifras: Cientos de millones
Fuente: (Elaboración Propia, 2024)

La varianza de los residuos muestra que el filtro desarrollado por el DEI logra una mayor reducción del ruido en la serie de microcréditos de BANHCAFE, alcanzando una varianza de 10,457, significativamente menor en comparación con la varianza de 32,073 del filtro Savitzky-Golay y la varianza de 44,328 de la serie original. Esto indica que el filtro DEI es más efectivo en la atenuación de las fluctuaciones no explicadas, reduciendo de manera drástica el componente aleatorio de la serie.

4.3.1.3 MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE BANHCAFE

Al aplicar el modelo predictivo auto regresivo a las series temporales (filtro Savitzky-Golay, filtro DEI, Original) de la cartera de préstamos de BANHCAFE Microcrédito, se obtuvieron los siguientes resultados.




Figura 19. Predicción Auto Regresiva: Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)

En la Figura 19 se observa que las predicciones sin aplicar ningún filtro presentan un comportamiento más plano, indicando una tendencia a subestimar los valores reales, en cambio, el filtro DEI sigue una trayectoria más cercana a los datos reales, aunque con menor volatilidad. Por su parte, el filtro Savitzky-Golay tiende a sobreestimar los valores, mostrando una tendencia ascendente más pronunciada, esto sugiere que el filtro DEI proporciona una predicción más conservadora y ajustada, mientras que el filtro SG puede exagerar las tendencias al suavizar menos la serie.

Aunque visualmente se observa que el filtro DEI ofrece una predicción más precisa en comparación con los otros métodos, es fundamental evaluar la eficacia de cada filtro utilizando métricas estadísticas. La Tabla 4 presenta los resultados numéricos de estas métricas obtenidas con el modelo AR, lo que permite determinar de manera objetiva cuál filtro proporciona una mejor

precisión en las predicciones.

Tabla 4. Métricas del Modelo AR: Serie de Microcréditos de BANHCAFE

Serie BANHCAFE Microcréditos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	9,792	3,129	2,947
Original	29,175	5,401	4,187
Filtro Savitzky-Golay	57,228	7,565	6,918

Fuente: (Elaboración Propia, 2024)

La serie filtrada con el Filtro DEI muestra un mejor desempeño, con los valores más bajos de Error Cuadrático Medio, Raíz del Error Cuadrático Medio y Error Absoluto Medio, lo que indica que el filtrado ha reducido el ruido, permitiendo al modelo capturar mejor los patrones subyacentes. La serie original, con métricas intermedias, sugiere un mayor nivel de ruido que afecta la precisión del modelo. Por último, la serie filtrada con Savitzky-Golay presenta las métricas más altas, indicando que este filtro no logró mejorar la calidad de los datos para esta serie en particular, posiblemente debido a la introducción de distorsiones adicionales o a una reducción insuficiente del ruido.

4.3.1.4 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) PARA LA SERIE DE BANHCAFE

Analizando la función de autocorrelación y la función de autocorrelación parcial de la serie de tiempo, sus resultados se muestran en la siguiente figura:

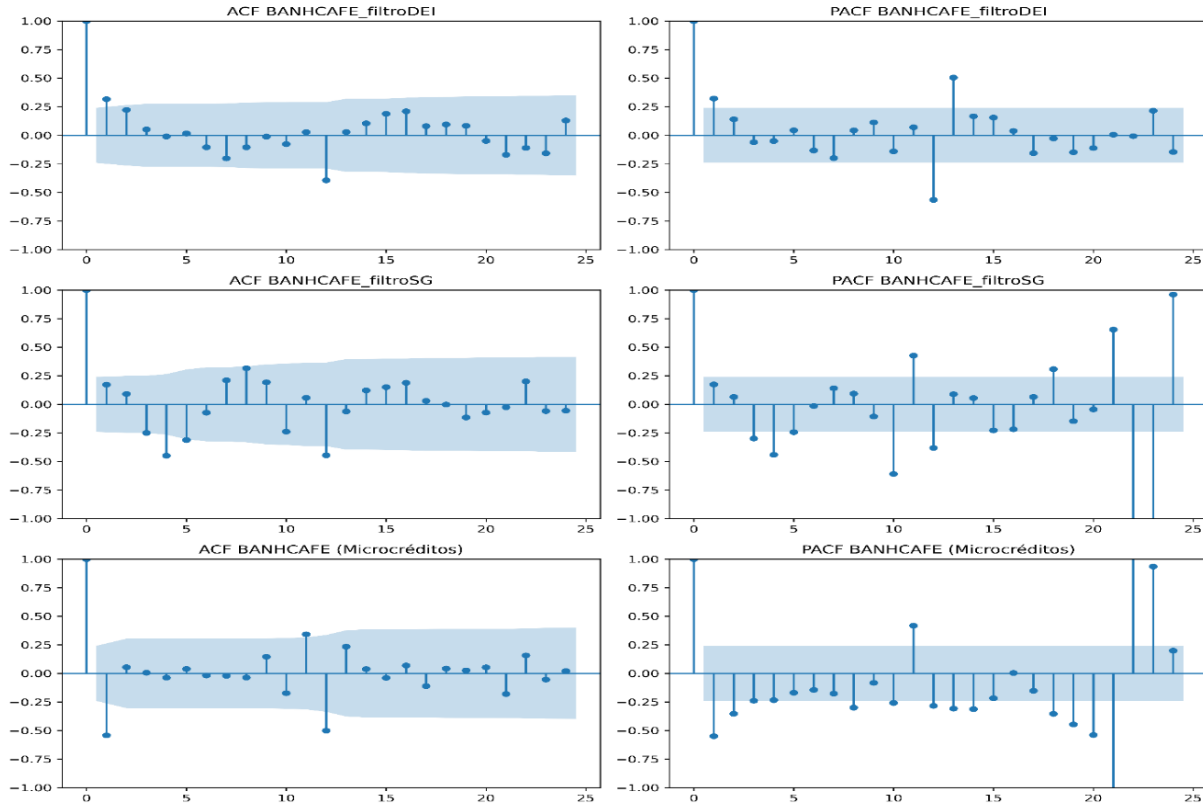


Figura 20. Análisis ACF y PACF: Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)

Al analizar los resultados presentados en la Figura 20, podemos obtener los valores p y q que rigen el orden de nuestro modelo ARIMA, donde p es el orden del componente autorregresivo (AR), determinado por el PACF y q es el orden del componente de media móvil (MA), determinado por el ACF, al inicio de la Sección 4.2.2 establecimos algunas consideraciones donde a cada serie se le aplicó una prueba de estacionalidad y se determinó que las series son estacionarias a dos diferencias, por lo tanto los componentes del orden de cada serie para el modelo ARIMA es el siguiente:

Tabla 5. Orden del modelo ARIMA: Microcréditos BANHCAFE

Serie BANHCAFE Microcréditos	Orden (p,d,q)
Filtro DEI	3,2,1
Original	2,2,1
Filtro Savitzky-Golay	1,1,1

Fuente: (Elaboración Propia, 2024)

Aplicando el orden a cada serie se obtuvo las siguientes predicciones:




Figura 21. Predicción ARIMA: Microcréditos BANHCAFE

Fuente: (Elaboración Propia, 2024)

En la Figura 21 muestra que la serie del filtro DEI proporciona una mejor serie para la predicción en comparación que con el filtro de Savitzky-Golay y la serie original, en la siguiente tabla se muestran las métricas para comparar el rendimiento de las series en comparación con las

predicciones generadas por el modelo ARIMA.

Tabla 6. Métricas del Modelo ARIMA: Serie de Microcréditos de BANHCAFE

Serie BANHCAFE Microcréditos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	2,526	1,589	1,213
Original	11,848	3,442	2,824
Filtro Savitzky-Golay	13,354	3,654	3,284

Fuente: (Elaboración Propia, 2024)

Las métricas de evaluación para la serie de microcréditos de BANHCAFE, comparando el desempeño del modelo ARIMA sobre la serie original y las series filtradas con el Filtro DEI y el Filtro Savitzky-Golay, los resultados indican que la serie filtrada con el Filtro DEI produce mejores predicciones, mostrando menores valores en el Error Cuadrático Medio (2,526), la Raíz del Error Cuadrático (1,589) y el Error Absoluto Medio (1,213), en comparación con la serie original y la filtrada con el Filtro Savitzky-Golay.

4.3.2 ANÁLISIS DE LA CARTERA DE PRÉSTAMOS PROMERICA DEL DESTINO INDUSTRIA

En esta sección se muestran los resultados obtenidos al aplicar la metodología propuesta a la serie de tiempo de la cartera de préstamos del destino Industria del banco PROMERICA.

4.3.2.1 FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE PROMERICA

Al comparar los resultados obtenidos mediante dos métodos de filtrado aplicados que incluyen el filtro desarrollado por el DEI y el filtro de Savitzky-Golay. La comparación busca evaluar la efectividad de cada filtro en la representación de la tendencia y la reducción de ruido en la serie temporal.

La Figura 22 muestra los resultados obtenidos al aplicar el filtro de Savitzky-Golay a la

serie de tiempo, se observa que el filtro permite una representación fiel de la tendencia sin alterar las características de la serie ya que se observan algunos picos en la serie filtrada. En el análisis de los residuos, la distribución empírica de los residuos es comparada con una distribución normal teórica, ofreciendo una medida adicional sobre la calidad del filtrado.




Figura 22. Aplicación del filtro de Savitzky-Golay a la Serie del Destino Industria de PROMERICA

Fuente: (Elaboración Propia, 2024)




Figura 23. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie del Destino Industria de PROMERICA

Fuente: (Elaboración Propia, 2024)

Como se observa en la Figura 24, el filtro desarrollado por el DEI suaviza variaciones abruptas, aunque en ciertos puntos de alta variabilidad se observan discrepancias entre la serie original y la filtrada. En el gráfico siguiente (Figura 25), se presenta el análisis de los residuos, incluyendo un histograma de su distribución comparado con una distribución teórica normal, lo cual permite evaluar la alineación de los residuos con una distribución normal y, por ende, la eficiencia del filtro en la reducción de ruido.




Figura 24. Aplicación del filtro DEI a la Serie del Destino Industria de PROMERICA

Fuente: (Elaboración Propia, 2024)




Figura 25. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie del Destino Industria de PROMERICA

Fuente: (Elaboración Propia, 2024)

Ambos métodos proporcionan representaciones útiles de la tendencia subyacente en la serie temporal, aunque presentan diferencias en el ajuste de los residuos a una distribución normal. El método DEI parece ser más eficaz en la suavización de variaciones abruptas, mientras que el filtro de Savitzky-Golay permite una representación de la tendencia con menos alteración de la señal original, lo cual puede ser preferible en contextos donde la preservación de las características originales es fundamental.

4.3.2.2 DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA PROMERICA

La descomposición de la serie de tiempo de PROMERICA utilizando tres métodos: el original sin filtrar, el filtrado con Savitzky-Golay (SG) y el filtro desarrollado por el DEI se presenta en cuatro componentes: el valor observado, la tendencia, la estacionalidad y los residuos. Se compara cómo cada filtro afecta la serie de tiempo y sus componentes, destacando las diferencias en la suavidad de la tendencia, la captación de patrones estacionales y la reducción del ruido en los residuos.




Figura 26. Descomposición de Serie Temporal: Destino Industria PROMERICA

Fuente: (Elaboración Propia, 2024)

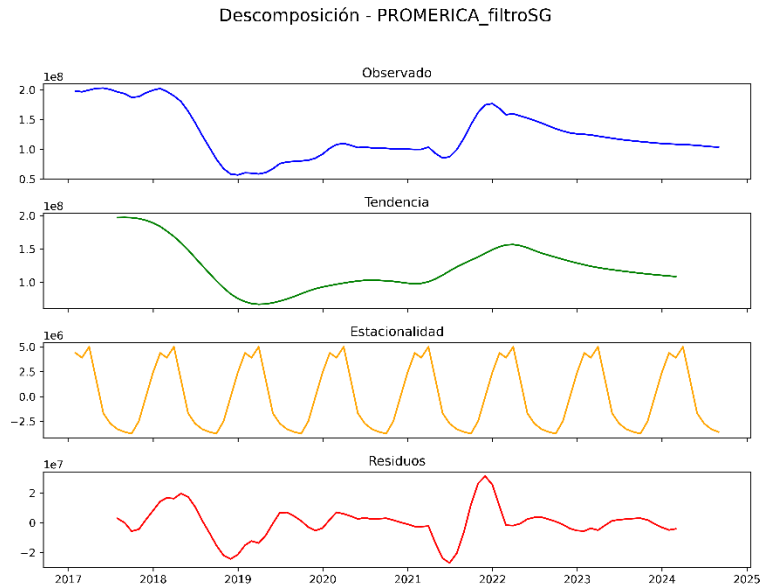


Figura 27. Descomposición de Serie Temporal: Filtro Savitzky-Golay Destino Industria PROMERICA

Fuente: (Elaboración Propia, 2024)




Figura 28. Descomposición de Serie Temporal: Filtro DEI Destino Industria PROMERICA

Fuente: (Elaboración Propia, 2024)

La descomposición de la serie muestra que el filtro Savitzky-Golay (SG) suaviza la tendencia y reduce el ruido, pero conserva la estacionalidad con menor amplitud, el filtro DEI, por

su parte, ofrece una tendencia más clara y estable, capturando cambios significativos hacia 2023, y mantiene la estacionalidad similar al filtro SG. Los residuos del filtro DEI son menores, lo que indica una mejor eliminación del ruido en comparación con el SG lo que sugiere que, el filtro DEI parece proporcionar una representación más precisa de la serie, mejorando tanto la detección de la tendencia como la reducción del componente aleatorio.

Tabla 7. Análisis de Varianza de los Residuos para la Serie de Destino Industria de PROMERICA

Serie PROMERICA Destino: Industrial	Varianza de los Residuos
Original	182,924
Filtro Savitzky-Golay	123,096
Filtro DEI	60,887

Escala de las cifras: Cientos de millones

Fuente: (Elaboración Propia, 2024)

La varianza de los residuos para la serie PROMERICA revela diferencias claras en el desempeño de los métodos de filtrado, la varianza de los residuos de la serie original es de 182,924, lo que indica una alta presencia de ruido o variabilidad no explicada. Al aplicar el filtro de Savitzky-Golay, la varianza se reduce a 123,096, mostrando una disminución significativa del ruido al suavizar la serie sin perder demasiados detalles. Sin embargo, el filtro desarrollado por el DEI logra una mayor reducción de la varianza, alcanzando un valor de 60,887, lo que sugiere que este filtro es más efectivo para eliminar el componente aleatorio.

4.3.2.3 MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DE PROMERICA

Tras implementar un modelo autorregresivo (AR) a las series temporales (filtro Savitzky-Golay, filtro DEI, Original) de la cartera de préstamos de PROMERICA, enfocada en el destino Industria, se obtuvieron los resultados descritos a continuación.

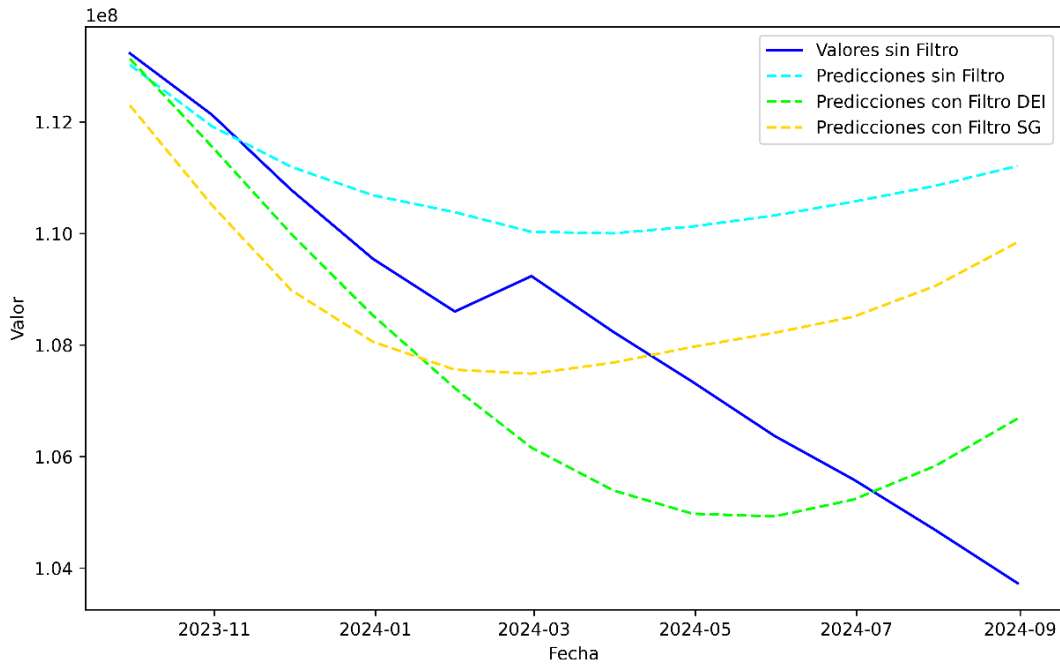


Figura 29. Predicción Auto Regresiva: Destino, Industria PROMERICA

Fuente: (Elaboración Propia, 2024)

En la Figura 29 se puede observar que las predicciones de las series con el filtro Savitzky-Golay, el filtro desarrollado por el DEI y la serie original sin filtro, no se ajustan bien a los datos de testeo e inclusive presentan una tendencia polinómica que se aleja en los últimos meses predichos. A pesar de las diferencias, el filtro DEI proporciona mejores resultados al momento de aplicar el método AR para predecir 12 meses, seguidos del filtro de Savitzky-Golay y por último la serie sin filtro.

Sin embargo, es importante analizar las métricas obtenidas del modelo AR, la siguiente tabla presenta las métricas más importantes para evaluar qué serie proporciona las mejoras predicciones.

Tabla 8. Métricas del Modelo AR: Destino, Industria PROMERICA

Serie PROMERICA Destino: Industrial	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	3,187	1,785	1,466
Filtro Savitzky-Golay	6,312	2,512	1,827
Original	12,578	3,546	2,642

Fuente: (Elaboración Propia, 2024)

La Tabla 8 presenta las métricas del modelo autorregresivo (AR) los resultados muestran que el filtro DEI proporciona el mejor desempeño, con los valores más bajos en el Error Cuadrático Medio (3,187), la Raíz del Error Cuadrático Medio (1,785) y el Error Absoluto Medio (1,466), indicando una mayor precisión en las predicciones. En contraste, el filtro Savitzky-Golay y la serie original presentan métricas significativamente más altas, siendo la serie original la menos precisa, con un Error Cuadrático Medio de 12,578 y un Error Absoluto Medio de 2,642.

4.3.2.4 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) PARA LA SERIE DE PROMERICA

Uno de los parámetros importantes dentro del ajuste de un modelo ARIMA es el orden del modelo, el orden se compone por tres elementos; el primero se determina por el número de diferencias que necesita una serie para que sea estacionaria y los otros dos elementos se obtienen del gráfico ACF y PACF, el análisis de estos gráficos son los siguientes.

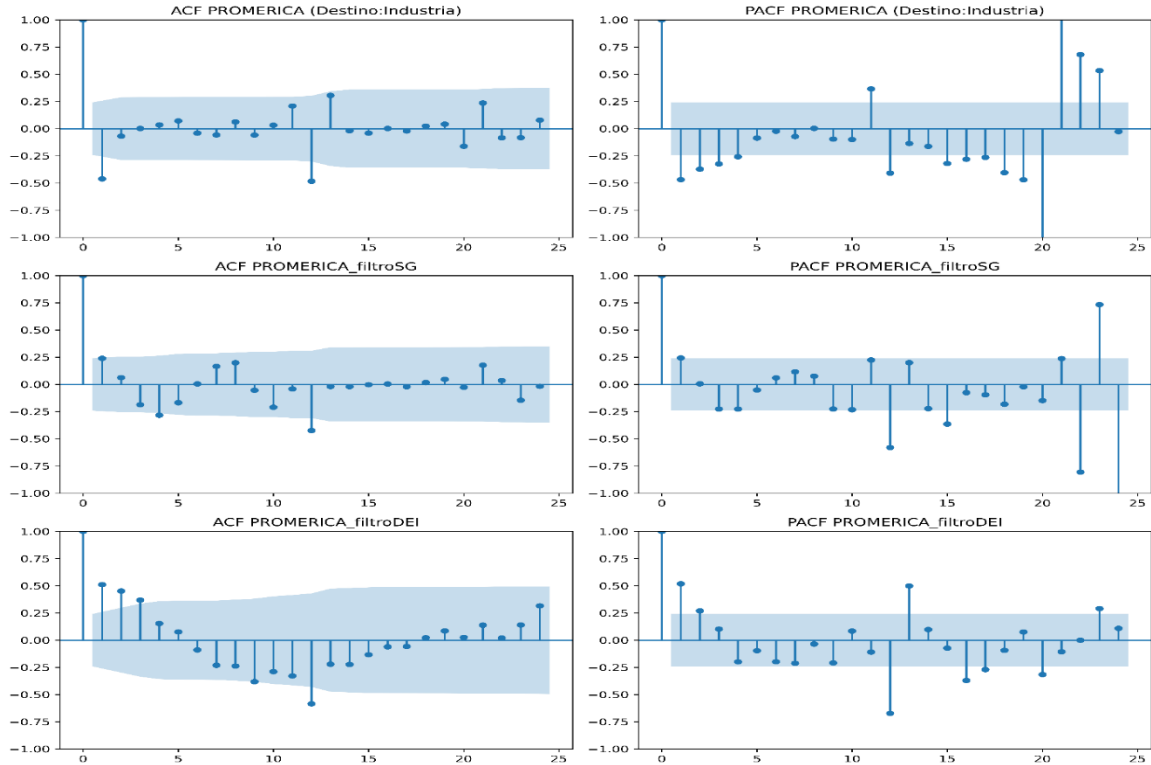


Figura 30. Análisis ACF y PACF: Destino Industria PROMERICA

Fuente: (Elaboración Propia, 2024)

La Figura 30 muestra dos gráficos para cada serie, del gráfico ACF se obtiene el orden de la componente de media móvil (MA) se le denota con la letra q y del gráfico PACF el orden del componente autorregresivo (AR) denotado con una letra p . Según la Figura 30 y con lo establecido con anterioridad sobre la necesidad de aplicar dos diferencias para desestacionalizar las series, la siguiente tabla muestra el orden de cada serie analizada.

Tabla 9. Orden del modelo ARIMA: Destino, Industria PROMERICA

Serie PROMERICA Destino: Industrial	ORDEN (p,d,q)
Filtro DEI	2,2,3
Original	2,2,1
Filtro Savitzky-Golay	2,2,3

Fuente: (Elaboración Propia, 2024)

Aplicando el orden a cada serie se obtuvo las siguientes predicciones:

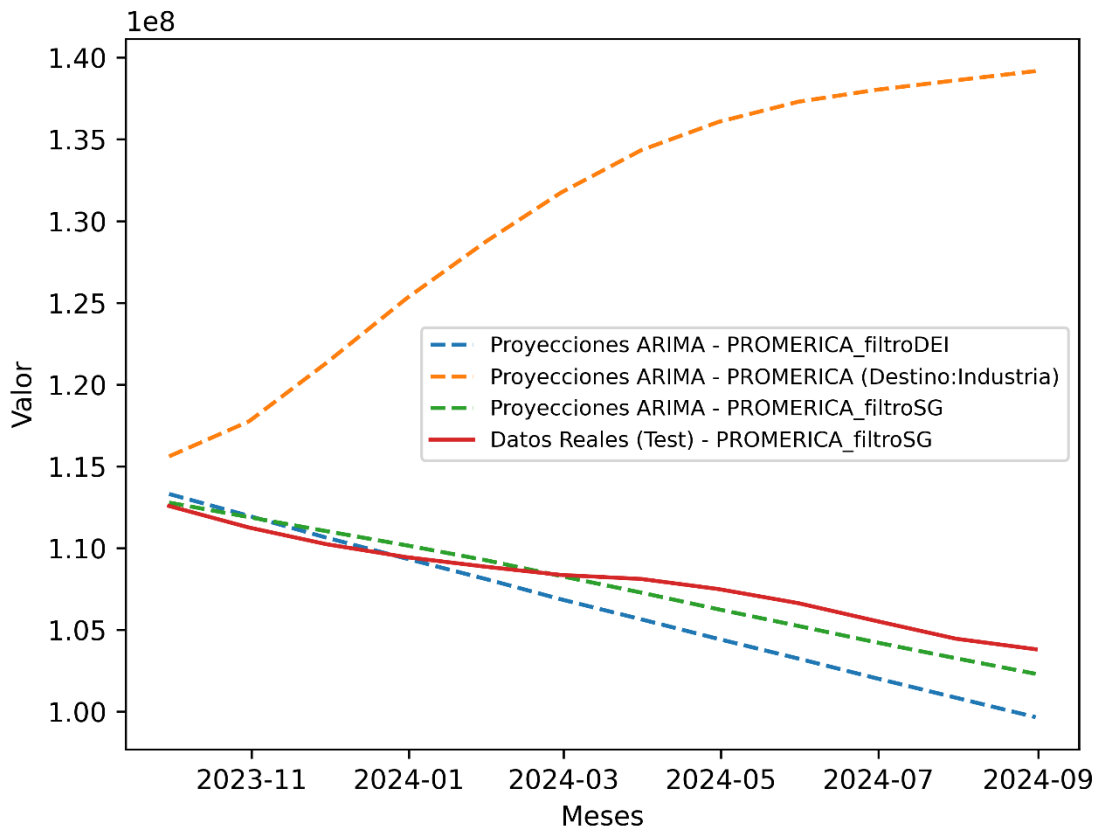


Figura 31. Predicción ARIMA: Destino Industria PROMERICA

Fuente: (Elaboración Propia, 2024)

En la Figura 31 a diferencia del modelo AR en el modelo ARIMA la serie que muestra mejores predicciones es la serie con el filtro de Savitzky-Golay en comparación que con el filtro DEI y la serie original, en la siguiente tabla se muestran las métricas para comparar el rendimiento de las series en comparación con las predicciones generadas por el modelo ARIMA.

Tabla 10. Métricas del Modelo ARIMA: Serie del Destino Industria de PROMERICA

Serie PROMERICA Destino: Industrial	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro Savitzky-Golay	944	972	858
Filtro DEI	6,118	2,473	2,029
Original	606,767	24,633	22,261

Fuente: (Elaboración Propia, 2024)

El filtro Savitzky-Golay destaca con los mejores resultados, mostrando un Error Cuadrático Medio (944), una Raíz del Error Cuadrático (972) y un Error Absoluto Medio (858), lo que refleja una mayor precisión en las predicciones. En comparación, el filtro DEI exhibe métricas más altas, con un Error Cuadrático Medio de 6,118 y un Error Absoluto Medio de 2,029, mientras que la serie original presenta valores extremadamente elevados, con un Error Cuadrático Medio de 606,767 y un Error Absoluto Medio de 22,261.

4.3.3 ANÁLISIS DEL SALDO DE DEPÓSITOS DE LAFISE

Para esta sección se analizará la variable financiera saldo de depósitos para el banco LAFISE, siguiendo la metodología propuesta anteriormente.

4.3.3.1 FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DE LAFISE

Se aplica el filtro de Savitzky-Golay y un filtro alternativo desarrollado por el DEI a la serie de tiempo de depósitos al banco LAFISE con el fin de suavizar las fluctuaciones y atenuar el ruido presente en los datos permitiendo preservar las características importantes de la serie, al tiempo que elimina las irregularidades causadas por el ruido aleatorio

En la Figura 32 se muestra la aplicación del filtro de Savitzky-Golay a la serie de saldos de depósitos del banco LAFISE, el gráfico evidencia cómo el filtro suaviza la serie original, reduciendo las oscilaciones menores que son producto del ruido en los datos. A pesar de la atenuación de estas variaciones, la serie filtrada conserva la forma general y las tendencias principales de los saldos, lo que permite una mejor interpretación y análisis de los patrones subyacentes del comportamiento de los depósitos.

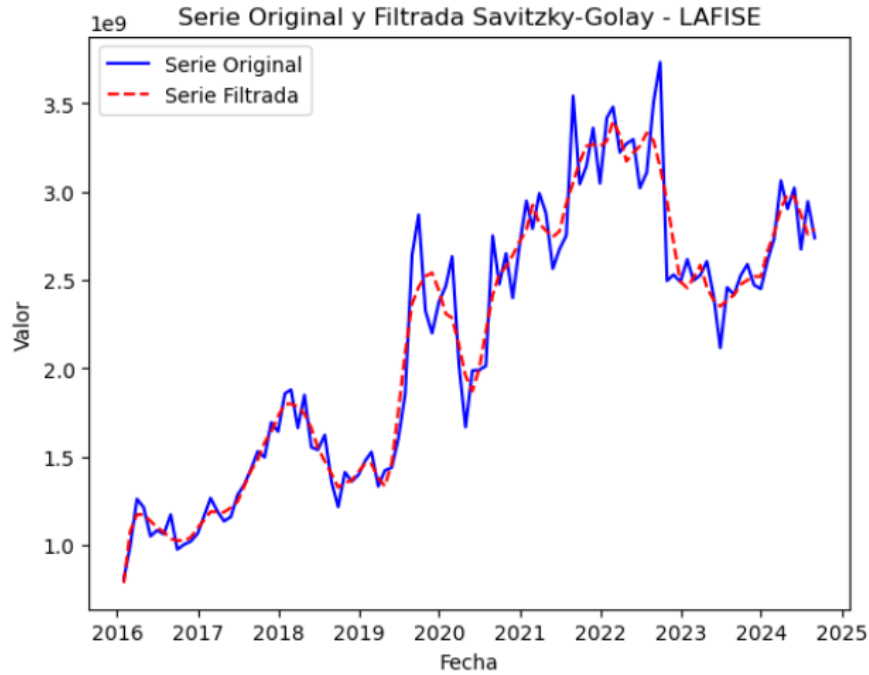


Figura 32. Aplicación del filtro de Savitzky-Golay a la Serie de Saldos de Depósitos para LAFISE

Fuente: (Elaboración Propia, 2024)

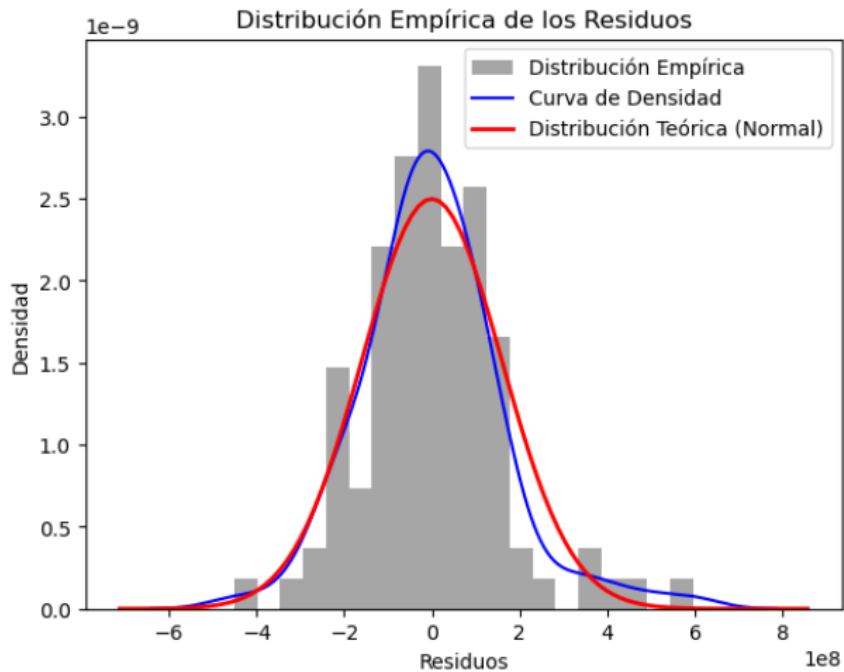


Figura 33. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Saldos de Depósitos para LAFISE

Fuente: (Elaboración Propia, 2024)

La Figura 34 ilustra nuevamente la aplicación del filtro desarrollado por el DEI a la serie de saldos de depósitos para LAFISE. En este caso, se observa una mayor suavización de la serie, lo que podría indicar un ajuste más agresivo que elimina tanto el ruido como parte de las fluctuaciones menores.




Figura 34. Aplicación del filtro DEI a la Serie de Saldos de Depósitos para LAFISE

Fuente: (Elaboración Propia, 2024)

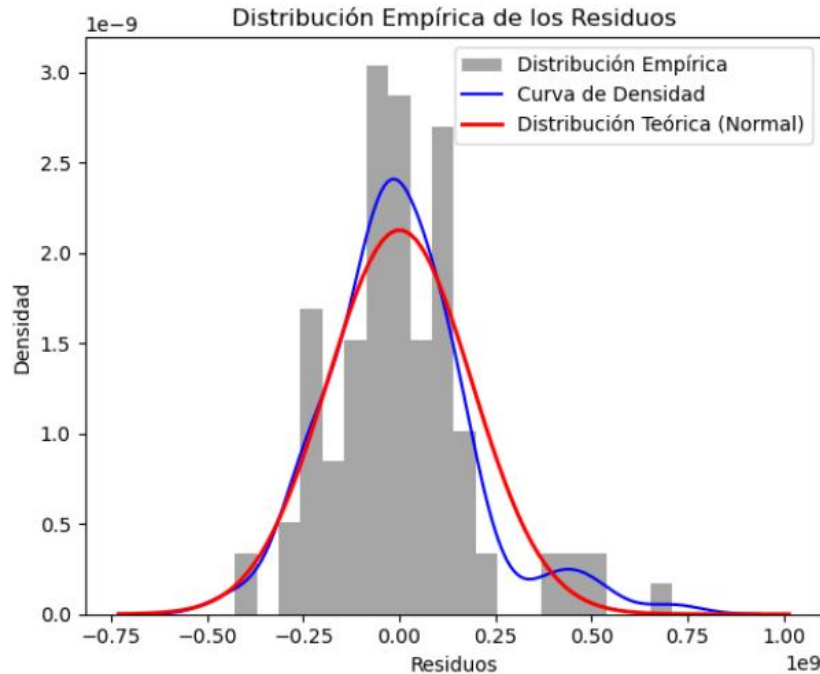


Figura 35. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Saldos de Depósitos para LAFISE

Fuente: (Elaboración Propia, 2024)

En general, mientras el filtro de Savitzky-Golay se enfoca en reducir el ruido preservando la estructura general de la serie, el filtro del DEI utiliza una técnica adaptativa que logra una suavización más agresiva, eliminando incluso algunas oscilaciones menores. Esto resulta en una serie más estable, la diferencia se presenta también en la distribución de los residuos, aunque se ve un buen ajuste por parte de los dos filtros se ve que el filtro del DEI parece ser más eficaz en la suavización de variaciones abruptas.

4.3.3.2 DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA LA SERIE DE LAFISE

La descomposición busca evaluar cómo cada método afecta la serie original en términos de suavización, extracción de tendencia, estacionalidad y residuos, permitiendo mediante gráficas visualizar claramente las diferencias en el desempeño de cada filtro y su impacto en la interpretación de los componentes de la serie temporal.




Figura 36. Descomposición de Serie Temporal: Saldo de Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)

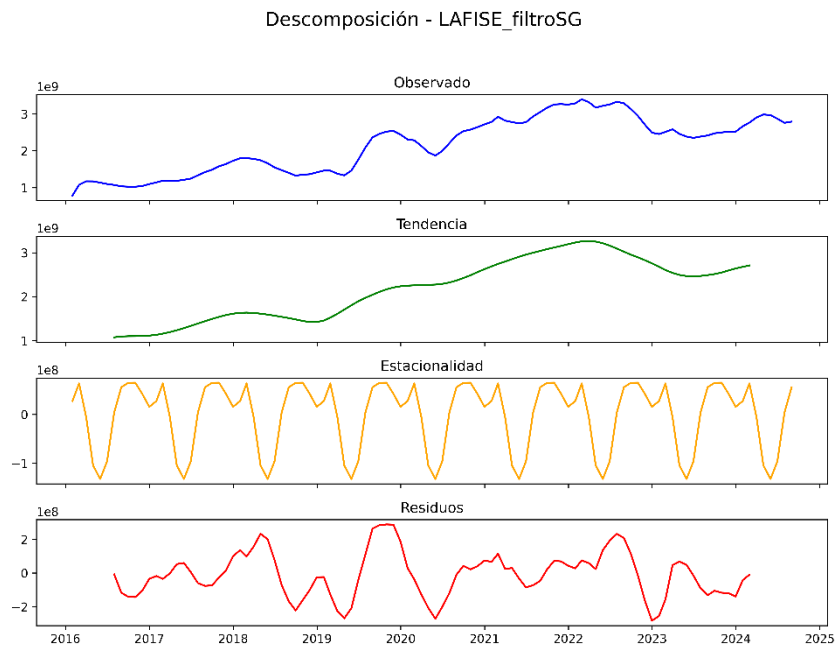


Figura 37. Descomposición de Serie Temporal: Filtro Savitzky-Golay Saldo de Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)




Figura 38. Descomposición de Serie Temporal: Filtro DEI Saldo de Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)

La Figura 37, muestra que el filtro de Savitzky-Golay logra suavizar la serie original, reduciendo el ruido sin alterar significativamente la estructura de la tendencia ni la estacionalidad, aunque los residuos conservan algunas fluctuaciones notables. Por otro lado, en la Figura 38, el filtro del DEI presenta una suavización más pronunciada, con una tendencia más marcada y menos fluctuaciones en los residuos, lo que indica una mayor eliminación del ruido, sin embargo, este filtro también reduce la amplitud de la estacionalidad, lo que podría implicar la pérdida de información relevante para algunos análisis.

Por lo anterior, se observa que el filtro del DEI parece ser más efectivo para obtener una serie más estable, mientras que el Savitzky-Golay preserva más características de la serie original, especialmente en los componentes estacionales y residuales.

Tabla 11. Análisis de Varianza de los Residuos para la Serie de Saldo de Depósitos de LAFISE

Serie LAFISE Saldo Depósitos	Varianza de los Residuos
Original	39,162,800
Filtro Savitzky-Golay	19,109,605
Filtro DEI	8,230,702

Escala de las cifras: Cientos de millones

Fuente: (Elaboración Propia, 2024)

La Tabla 11 muestra la varianza de los residuos tras aplicar los filtros a la serie de saldos de depósitos para LAFISE. La varianza inicial de los residuos en la serie original es de 39,162,800, con el filtro de Savitzky-Golay, la varianza se reduce casi a la mitad, alcanzando 19,109,605, lo que indica una eliminación efectiva del ruido pero conservando cierta variabilidad, por último, el filtro del DEI muestra una reducción aún mayor, con una varianza de 8,230,702, evidenciando una suavización más agresiva, lo que puede sugerir que el filtro del DEI es más efectivo para minimizar la variabilidad residual, aunque podría sacrificar parte de las fluctuaciones menores presentes en la serie original.

4.3.3.3 MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DE LAFISE

Al aplicar el modelo autorregresivo (AR) a las series temporales (filtro Savitzky-Golay, filtro DEI, Original) de depósitos del banco LAFISE, se obtuvieron las siguientes predicciones.




Figura 39. Predicción Auto Regresiva: Saldo Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)

En la Figura 39 se muestran las predicciones de las series sin filtro y las series con el filtro de Savitzky-Golay y el desarrollado por el DEI. Se observa que la serie original sin filtro proporciona una serie de predicciones que sigue la forma de la serie original con unas diferencias en los saldos de depósitos, por otro lado, la serie del filtro DEI proporciona una serie de predicciones más plana sin volatilidad asemejándose más a la tendencia de la serie original. Por último, la serie con el filtro de Savitzky-Golay es la que proporciona las peores predicciones ya que su serie se ve bien alejada de los valores reales.

Aunque es visualmente evidente que el filtro DEI proporciona una mejor serie de predicciones al momento de aplicar el modelo AR, es importante evaluar las métricas que obtenemos del modelo.

Tabla 12. Métricas del Modelo AR: Depósitos LAFISE

Serie LAFISE Saldo Depósitos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	11,598,613	107,697	94,154
Original	94,736,228	307,793	270,882
Filtro Savitzky-Golay	95,750,587	309,436	255,176

Fuente: (Elaboración Propia, 2024)

La Tabla 12 de la serie de Saldo de Depósitos de LAFISE destacan que el Filtro DEI logra un desempeño superior, con los valores más bajos en el Error Cuadrático Medio (11,598,613), la Raíz del Error Cuadrático (107,697) y el Error Absoluto Medio (94,154). En contraste, la serie original y la filtrada con el Filtro Savitzky-Golay presentan errores significativamente más altos, indicando que el Filtro DEI es más eficiente para optimizar las predicciones al reducir el ruido en la serie.

4.3.3.4 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) PARA LA SERIE DE LAFISE

El orden del modelo ARIMA se determina por tres componentes; el número de diferencias que necesita una serie para que sea estacionaria y los otros dos elementos se obtienen del gráfico ACF y PACF, el análisis de estos gráficos son los siguientes.

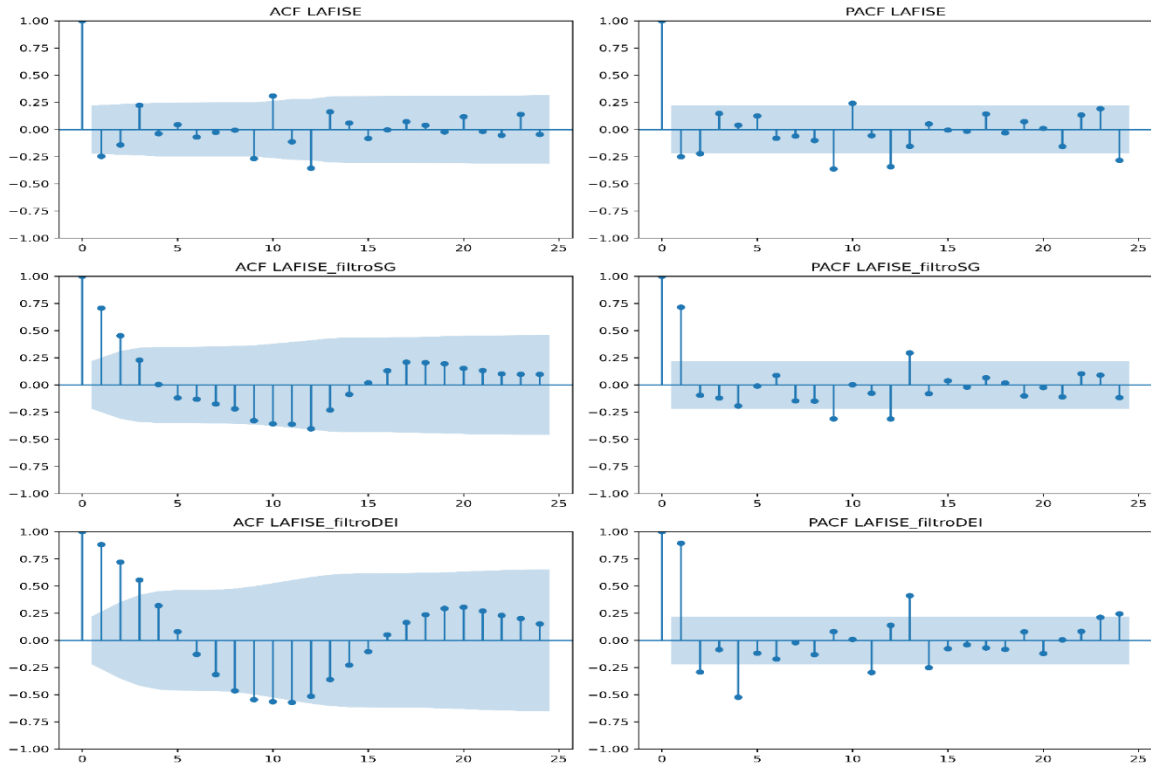


Figura 40. Análisis ACF y PACF: Saldo Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)

Al igual que el análisis de las gráficas ACF y PACF de las series anteriores aquí debemos determinar el orden del modelo ARIMA, así mismo, seguimos considerando los dos diferencias que le aplicamos a las series para hacerlas estacionarias, la siguiente tabla muestra el orden para cada serie temporal (filtro DEI, filtro Savitzky-Golay, Original).

Tabla 13. Orden del modelo ARIMA: Depósitos LAFISE

Serie LAFISE Saldo Depósitos	ORDEN (p,d,q)
Filtro DEI	1,2,3
Original	1,2,2
Filtro Savitzky-Golay	1,1,1

Fuente: (Elaboración Propia, 2024)

Aplicando el orden a cada serie se obtuvo las siguientes predicciones:




Figura 41. Predicción ARIMA: Saldo Depósitos de LAFISE

Fuente: (Elaboración Propia, 2024)

En la Figura 41 al igual que el modelo AR, la serie con el filtro DEI proporciona las mejores predicciones al momento de aplicar el modelo ARIMA, la serie sin filtro original parece replicar el mismo comportamiento de la serie de testeo, por último, el filtro de Savitzky-Golay es el que se aleja en los últimos meses de predicción. En la siguiente tabla se muestran las métricas obtenidas del modelo ARIMA.

Tabla 14. Métricas del Modelo ARIMA: Serie de Depósitos de LAFISE

Serie LAFISE Saldo Depósitos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	11,598,613	107,697	94,154
Original	94,736,228	307,793	270,882
Filtro Savitzky-Golay	95,750,587	309,436	255,176

Fuente: (Elaboración Propia, 2024)

Los resultados muestran que el filtro DEI ofrece un desempeño significativamente superior, con el Error Cuadrático Medio (11,598,613), la Raíz del Error Cuadrático (107,697) y el Error Absoluto Medio (94,154) más bajos, lo que indica predicciones más precisas. En contraste, la serie original y el filtro Savitzky-Golay presentan métricas mucho mayores, siendo estos últimos bastante similares entre sí, con errores absolutos medios de 270,882 y 255,176 respectivamente.

4.3.4 ANÁLISIS DE LAS TRANSACCIONES DE DEPÓSITOS DEL BANCO HONDURAS

Para esta sección se analizará la variable financiera transacciones de depósitos de la cuenta de ahorro para el banco HONDURAS, siguiendo la metodología propuesta anteriormente.

4.3.4.1 FILTRO DE SAVITZKY-GOLAY Y FILTRO DE AJUSTE POR POLINOMIO LOCAL DEI PARA LA SERIE DEL BANCO HONDURAS

Al graficar los resultados al aplicar los dos métodos de filtrado a la variable financiera de las transacciones de depósitos del banco HONDURAS, al comparar cada filtro se busca estudiar qué tan efectivo es cada filtro en la reducción de ruido en la serie temporal.

La Figura 42 presenta el análisis utilizando el método Savitzky-Golay, donde el suavizado reduce el ruido manteniendo la tendencia general de los datos entre 2012 y 2024. Se analiza la distribución de los residuos, evidenciada por un histograma y una curva de densidad empírica donde los residuos muestran una distribución simétrica con algunas desviaciones respecto a la

distribución normal.




Figura 42. Aplicación del filtro de Savitzky-Golay a la Serie de Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)




Figura 43. Distribución Empírica de los Residuos: Aplicación del filtro de Savitzky-Golay a la Serie de Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

En la Figura 44 se muestran los resultados al aplicar el filtro DEI el suavizado sigue la tendencia general, con ligeras diferencias en la precisión del ajuste en picos específicos, a comparación con el filtro de Savitzky-Golay el filtro DEI suaviza de manera más estricta la serie disminuyendo significativamente los picos de la serie original, este ajuste provoca variaciones en las colas de la distribución de los residuos, sugiriendo ligeras discrepancias en el ajuste.




Figura 44. Aplicación del filtro DEI a la Serie de Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

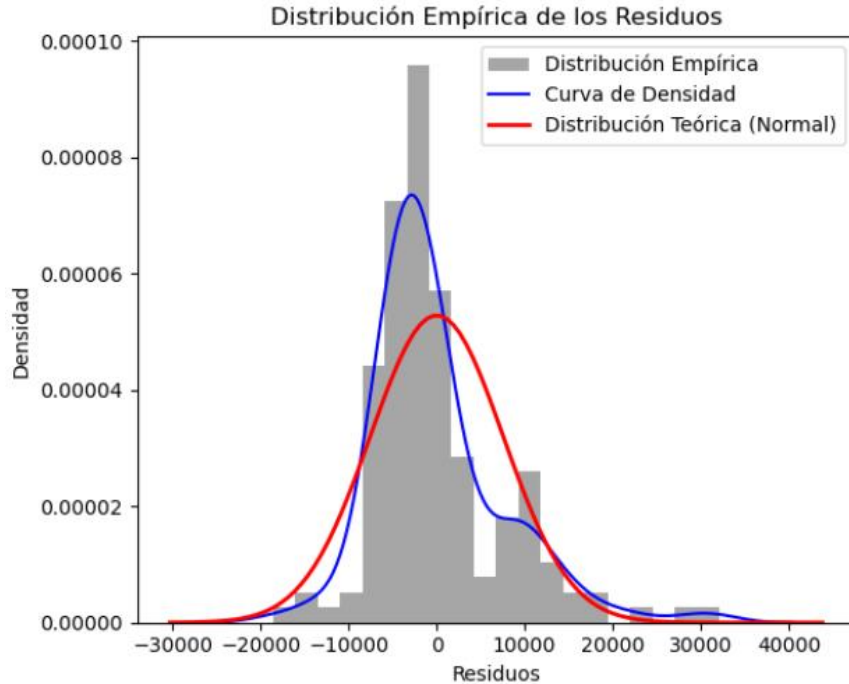


Figura 45. Distribución Empírica de los Residuos: Aplicación del filtro DEI a la Serie de Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

El ajuste del filtro DEI parece más estricto al momento de suavizar los picos, así mismo, los residuos muestran un mayor rango y una curva de densidad con desviaciones más notorias en las colas respecto a la normal teórica. Por otra parte, el filtro de Savitzky-Golay se ajusta mejor a la serie original permitiendo mayores oscilaciones que se traduce a una menor reducción del ruido.

4.3.4.2 DESCOMPOSICIÓN DE SERIES DE TIEMPO PARA EL BANCO HONDURAS

Se presenta un análisis de la descomposición de una serie temporal para la variable de transacciones de depósitos del banco Honduras y sus versiones suavizadas utilizando dos métodos de filtrado: Savitzky-Golay y el filtro DEI. La descomposición separa la serie en sus componentes principales: tendencia, estacionalidad y residuos, lo que permite identificar patrones subyacentes y evaluar el impacto de cada método de suavizado en la estructura de los datos.




Figura 46. Descomposición de Serie Temporal: Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)




Figura 47. Descomposición de Serie Temporal: Filtro Savitzky-Golay Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)




Figura 48. Descomposición de Serie Temporal: Filtro DEI Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

Las figuras muestran el análisis de descomposición de la serie temporal de las transacciones de depósitos del banco Honduras y sus versiones suavizadas mediante los filtros Savitzky-Golay y el filtro DEI. En la fila de datos observados, los filtros reducen el ruido manteniendo la tendencia general, aunque el filtro DEI parece suavizar más agresivamente los datos, en la muestra de la tendencia esta revela patrones similares a largo plazo en ambos filtros, aunque el filtro DEI presenta una mayor uniformidad. En la tercera fila, correspondiente a la estacionalidad, se identifican patrones cíclicos consistentes en las tres series, aunque los filtros suavizan ligeramente las oscilaciones y, por último, los residuos, en la última fila, muestran que el filtro SG conserva mayor amplitud en las irregularidades, mientras que el filtro DEI las reduce, reflejando un ajuste más restrictivo.

Tabla 15. Análisis de Varianza de los Residuos para la Serie de Transacciones de Depósitos del Banco HONDURAS

Serie Honduras Transacciones de Depósitos	Varianza de los Residuos
Original	35,000
Filtro Savitzky-Golay	13,000
Filtro DEI	3,000

Escala de las cifras: En millones

Fuente: (Elaboración Propia, 2024)

La Tabla 15, muestra que la varianza de los residuos en la serie original es de 35,000, reflejando alta volatilidad, al aplicar el filtro de Savitzky-Golay, la varianza se reduce a 13,000, evidenciando una disminución significativa del ruido. Sin embargo, el filtro desarrollado por el DEI logra reducir la varianza aún más, hasta 3,000, demostrando una mayor eficacia en la suavización de la serie y en la eliminación del ruido, estos resultados indican que el filtro DEI es superior para mejorar la calidad de los datos en este contexto.

4.3.4.3 MODELO DE PREDICCIÓN AUTO REGRESIVO (AR) PARA LA SERIE DEL BANCO HONDURAS

Se implementó un modelo autorregresivo (AR) a la serie con el filtro de Savitzky-Golay, con filtro DEI, y la serie Original sin filtro, los resultados se muestran a continuación.




Figura 49. Predicción Auto Regresiva: Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

Al igual que el modelo AR presentado en las series anteriores, en la Figura 49 se puede observar que las predicciones de la serie original responden a casi el mismo comportamiento de la serie de testeo. Por otro lado, las series con los filtros parecen ser más planas con algunas diferencias de saldos uno con la otra, a simple vista es difícil de comprobar que serie de tiempo proporciona las mejores predicciones. Por lo anterior, es importante analizar las métricas obtenidas por el modelo para poder evaluar qué serie proporciona las mejores predicciones.

Tabla 16. Métricas del Modelo AR: Transacciones de Depósitos Banco HONDURAS

Serie Honduras Transacciones de Depósitos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro DEI	14,326	3,784.9	3,217.5
Filtro Savitzky-Golay	103,972	10,196.7	8,479.4
Original	124,772	11,170.1	7,737.8

Fuente: (Elaboración Propia, 2024)

Los datos de la Tabla 16 muestran que la serie filtrada con el filtro DEI obtiene los errores más bajos, con un Error Cuadrático Medio de 14,326, una Raíz del Error Cuadrático de 3,784.9 y un Error Absoluto Medio de 3,217.5. En contraste, la serie original y la filtrada con el filtro Savitzky-Golay presentan errores considerablemente mayores.

4.3.4.4 MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA) DEL BANCO HONDURAS

El orden del modelo ARIMA se determina por tres componentes; el número de diferencias que necesita una serie para que sea estacionaria y los otros dos elementos se obtienen del gráfico ACF y PACF, el análisis de estos gráficos son los siguientes.

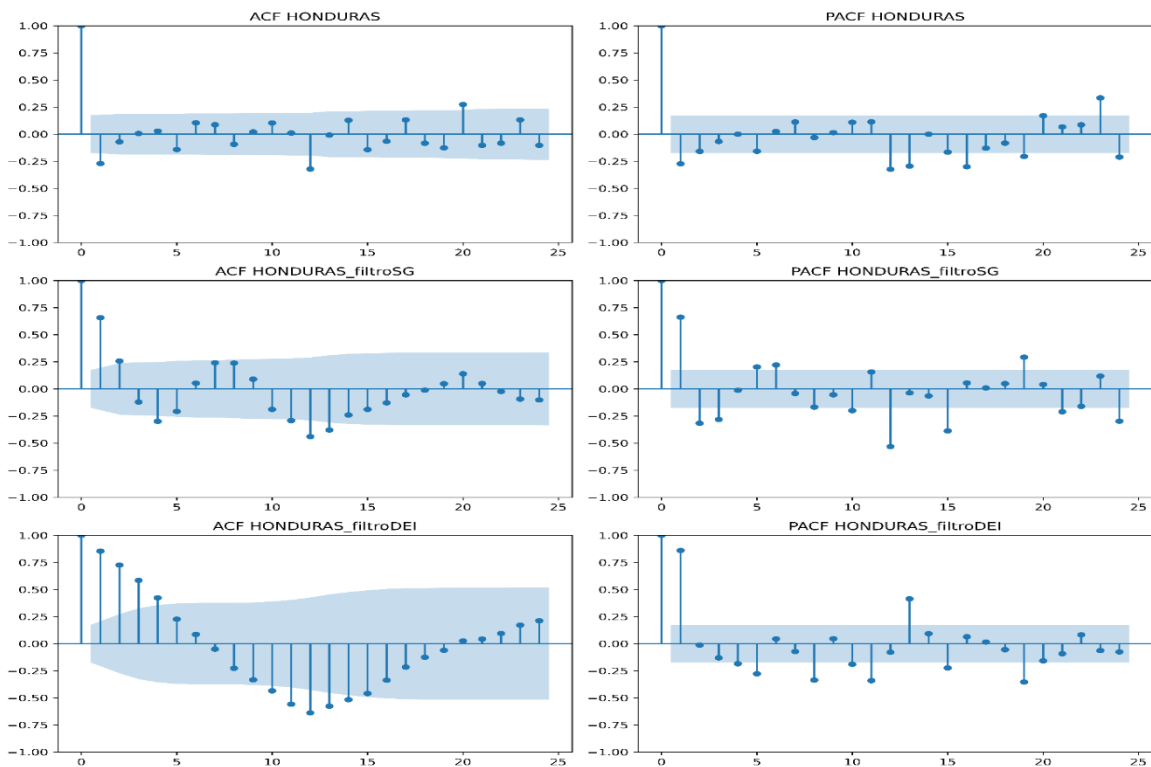


Figura 50. Análisis ACF y PACF: Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

Es importante recordar que para los componentes del orden del modelo ARIMA, la componente de las diferencias lo establecimos con anterioridad con una prueba de estacionalidad,

esta prueba nos arrojó que la serie es estacionaria a dos diferencias, por otro lado, las demás componentes del orden se deducen de la Figura 50.

Tabla 17. Orden del modelo ARIMA: Transacciones de Depósitos del Banco HONDURAS

Serie Honduras Transacciones de Depósitos	ORDEN (p,d,q)
Filtro DEI	1,2,2
Original	1,2,2
Filtro Savitzky-Golay	1,1,0

Fuente: (Elaboración Propia, 2024)

Aplicando el orden a cada serie se obtuvo las siguientes predicciones:




Figura 51. Predicción ARIMA: Transacciones de Depósitos del Banco HONDURAS

Fuente: (Elaboración Propia, 2024)

La Figura 51 muestra las series de predicciones que se obtienen de cada serie de datos, en

esta figura se muestra que las series con filtro Savitzky-Golay y la serie original sin filtro, proporciona predicciones que siguen la tendencia de la serie original. En contraste, la serie con el filtro desarrollado por el DEI proporciona una serie más plana sin mucha volatilidad, la siguiente tabla muestra las métricas que se obtienen del modelo ARIMA.

Tabla 18. Métricas del Modelo ARIMA: Serie de Transacciones de Depósitos del Banco HONDURAS

Serie Honduras Transacciones de Depósitos	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
Filtro Savitzky-Golay	32,489	5,699.9	3,912.9
Filtro DEI	37,928	6,158.6	4,832.3
Original	38,874	6,234.9	5,239.0

Fuente: (Elaboración Propia, 2024)

En la Tabla 18 los resultados, destaca que el filtro Savitzky-Golay proporciona el mejor desempeño, con los valores más bajos en el Error Cuadrático Medio (32,489), la Raíz del Error Cuadrático (5,699.9) y el Error Absoluto Medio (3,912.9), indicando mayor precisión en las predicciones. Por otro lado, el filtro DEI y la serie original presentan métricas similares, aunque el filtro DEI tiene un rendimiento ligeramente mejor que la serie sin filtrar, pero inferior al del filtro Savitzky-Golay.

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

Este capítulo presenta una síntesis de los hallazgos generados por el exhaustivo trabajo realizado en el análisis desarrollado durante esta investigación, se resaltan las implicaciones más relevantes de los resultados y cómo estos ayudan a entender el problema planteado. Este apartado busca entender de manera clara y concisa todos los logros alcanzados, destacando la importancia de esta investigación en el contexto del campo que se ha estudiado. Estos resultados deben de responder con los objetivos planteados inicialmente, así mismo deberá de contestar las preguntas de investigación planteadas, por otro lado, se proponen recomendaciones para futuras investigaciones o aplicaciones.

5.1 CONCLUSIONES

Esta investigación tuvo como objetivo comprender cómo la aplicación de filtros para suavizar series de tiempo con alta volatilidad puede mejorar su análisis, facilitar su comprensión y optimizar su estudio, con el fin de fortalecer la toma de decisiones con análisis de predicciones a variables financieras dinámicas y más complejas.

La investigación confirmó que los filtros de Savitzky-Golay y el filtro desarrollado por el Departamento de Estadísticas e Investigación (DEI), proporcionan mejoras significativas en la reducción de ruido y la preservación de características importantes de las series temporales. El uso de los filtros no solo optimizó la calidad del análisis de las tendencias, sino que también aumentó significativamente la precisión de las predicciones realizadas con los modelos AR y ARIMA, lo cual confirma la importancia de la aplicación de los filtros a variables del entorno financiero volátiles.

Según los resultados obtenidos en el Capítulo IV y analizando las preguntas de investigación específicas tenemos que:

1. La configuración óptima de los filtros, en términos del grado del polinomio y el tamaño de la ventana, depende de la naturaleza de los datos y del nivel de suavizado deseado. A medida que se incrementa el grado del polinomio y el tamaño de la ventana, el filtro elimina más eficazmente el ruido, pero también puede suprimir características

esenciales que resultan valiosas para realizar predicciones. Diversos estudios sugieren que el tamaño de la ventana debe coincidir con la cantidad de datos a predecir o ser lo suficientemente amplio para capturar la estacionalidad en las series de tiempo.

(Dombi y Dineva, 2020), en su estudio sobre el filtrado adaptativo Savitzky-Golay y sus aplicaciones, recomiendan utilizar un grado de polinomio igual a 5 para ventanas de tamaño 11 o mayor. En nuestro análisis, con el objetivo de predecir 12 meses hacia adelante, se decidió emplear una ventana de 13 meses y un grado de polinomio igual a 5, siguiendo las recomendaciones previas. Esta configuración se consideró óptima y se aplicó a cada variable de estudio utilizando tanto el filtro Savitzky-Golay como el filtro desarrollado por el DEI.

2. Ya se demostró en los análisis de los resultados que el filtro desarrollado por el DEI superó al filtro de Savitzky-Golay al reducir mejor el ruido latente en la serie de tiempo. En el análisis de descomposición de series temporales se calculó las varianzas de cada serie demostrando que el filtro del DEI es el que reduce significativamente la varianza de los residuos. Para los modelos AR el filtro DEI es el que proporcionó las mejores métricas de las predicciones en las diferentes variables que fueron analizadas, por otra parte, para el modelo ARIMA el filtro de Savitzky-Golay obtuvo buenos rendimientos en las predicciones de las series del banco HONDURAS y PROMERICA.
3. La descomposición de series temporales resultó una herramienta clave para analizar y comprender mejor cada componente de las series, este método permite separar las series en sus principales elementos: tendencia, estacionalidad y ruido, lo que facilita su interpretación al proporcionar una visión más clara y estructurada de su comportamiento. La identificación de la tendencia ayuda a reconocer los patrones subyacentes a largo plazo, la estacionalidad destaca los ciclos recurrentes, y el aislamiento del ruido permite enfocarse en los datos relevantes sin distracciones causadas por fluctuaciones aleatorias. Aunque la descomposición de series ofrece una perspectiva detallada y estructurada, no representa una limitación en el análisis de series temporales ya que, además, existen diversas métricas que pueden evaluar la efectividad del uso de filtros en series temporales.

El uso combinado de la descomposición con métricas adicionales para evaluar el rendimiento de los filtros ofrece un enfoque robusto para analizar su efectividad, donde no

solo mejora la comprensión de las series temporales, sino que también optimiza los modelos predictivos al asegurar que se preserven las características fundamentales de la serie.

4. El análisis exploratorio de datos (EDA) permitió examinar las variables financieras seleccionadas como base para los análisis y los resultados obtenidos en esta investigación. Los hallazgos del EDA revelaron que las variables financieras seleccionadas, elegidas por conveniencia, corresponden a bancos cuya participación en saldos o transacciones es más baja y se encuentran en los últimos lugares en comparación con el resto del entorno financiero. Este hallazgo sugiere que los bancos más pequeños tienden a mostrar una menor estabilidad en su volumen de transacciones y saldos, dificultando el mantenimiento de una tendencia lineal. Como resultado, estas entidades presentan una mayor volatilidad o ruido en sus tendencias a lo largo del tiempo.

Estas conclusiones no agotan las posibilidades de investigación sobre el uso de filtros para eliminar el ruido latente en series financieras con alta volatilidad. Como se mencionó anteriormente, la eficacia de estos filtros depende en gran medida de la naturaleza de los datos y de los objetivos específicos del investigador, particularmente en lo que respecta al ajuste de la ventana para las predicciones, por lo tanto, no existe una fórmula universal que permita suavizar todas las series de manera óptima.

5.2 RECOMENDACIONES

Con base en los conocimientos generados y los hallazgos alcanzados a lo largo de esta investigación, se proponen las siguientes recomendaciones con el objetivo de orientar futuras acciones:

1. Se recomienda ajustar cuidadosamente los parámetros de los filtros, como el tamaño de la ventana y el grado del polinomio, este ajuste se deberá aplicar en función de las características de la serie temporal analizada y de los objetivos planteados por el investigador. Esto permitirá tener un equilibrio adecuado entre la reducción del ruido y la preservación de las características esenciales de las series, también, reducirá el sobre ajuste de los modelos de predicción.
2. A pesar de que el filtro desarrollado por el Departamento de Estadísticas e

Investigación (DEI) ha demostrado ser más efectivo que el filtro de Savitzky-Golay en la reducción de ruido en series financieras con alta volatilidad, se recomienda utilizar ambos filtros. La investigación reveló que, en el modelo ARIMA aplicado a las variables de los bancos PROMERICA y HONDURAS, el filtro de Savitzky-Golay ofreció las mejores predicciones en comparación con el filtro DEI. Así mismo, se sugiere realizar análisis detallados para determinar cuál de los dos filtros genera las mejores predicciones en función de las características específicas de las variables analizadas.

3. Se recomienda complementar el uso de los filtros con herramientas como el análisis de varianzas de los residuos, la descomposición de series temporales para analizar las tendencias, la estacionalidad y el ruido por separado. Es crucial utilizar las métricas que se obtienen de los modelos AR y ARIMA para evaluar el desempeño de los filtros en la mejora de las predicciones.
4. Se recomienda continuar explorando métodos alternativos para realizar predicciones, combinándolos con diversos filtros existentes para abordar series de tiempo con características más complejas o específicas. Dado que no existe un filtro universal que se adapte a todas las series, esta combinación permitirá realizar predicciones a largo plazo con menor margen de error, asegurando un análisis más completo y dinámico que pueda ajustarse a diferentes variables financieras y contextos económicos.

Estas recomendaciones abren la puerta a futuras investigaciones sobre el uso de filtros para eliminar la volatilidad de las variables financieras, permitiendo avanzar en el desarrollo de herramientas más sofisticadas y adaptables. Además, invitan a explorar nuevas técnicas de combinación de filtros y modelos predictivos que puedan abordar los desafíos inherentes a las series temporales con alta complejidad que no solo fortalecerá la capacidad de análisis y predicción en el sector financiero, sino que también contribuirá a la toma de decisiones más informadas en un entorno económico cada vez más dinámico y cambiante.

CAPÍTULO VI. APLICABILIDAD

El análisis de datos financieros exige herramientas metodológicas capaces de identificar patrones y tendencias significativas en series temporales, las cuales suelen estar influenciadas por una alta volatilidad y la presencia de ruido.

En los capítulos anteriores se presentaron los fundamentos teóricos, la metodología utilizada, así como el análisis y los resultados de la investigación. Este capítulo, por su parte, se centra en cómo implementar la metodología en la Comisión Nacional de Bancos y Seguros (CNBS), proporcionando una guía práctica que permitirá a las áreas interesadas dentro de la institución aprovechar los beneficios de la propuesta desarrollada

6.1 NOMBRE DE LA PROPUESTA

Propuesta para la Implementación de Suavizado de Series Temporales con el Uso del Filtro de Savitzky-Golay y el Filtro Desarrollado por el DEI en Variables Financieras del Sector Hondureño

6.2 JUSTIFICACIÓN DE LA PROPUESTA

El análisis de series temporales financieras es esencial para comprender las dinámicas del sector financiero y tomar decisiones estratégicas basadas en datos confiables. Sin embargo, la presencia de ruido y fluctuaciones inesperadas puede dificultar la identificación de tendencias y patrones relevantes en estas series. Frente a este desafío, los métodos de suavizado estadístico se presentan como herramientas clave para mejorar la calidad y la interpretabilidad de los datos, permitiendo un análisis más robusto y preciso.

En este contexto, surge la pregunta: ¿Por qué es necesaria una metodología de suavizado de series temporales para la Comisión Nacional de Bancos y Seguros (CNBS)? La respuesta radica en la necesidad de garantizar análisis más claros y confiables, que sirvan de base para la formulación de políticas regulatorias y estrategias que fortalezcan la estabilidad del sector financiero.

El filtro de Savitzky-Golay, ampliamente reconocido en el procesamiento de señales, se

ha destacado por su capacidad para preservar la forma y las características de la señal durante el suavizado. Por otro lado, un filtro desarrollado específicamente por el Departamento de Estadística e Investigación ofrece una perspectiva innovadora que podría adaptarse mejor a las particularidades de las series financieras del sector hondureño. La implementación y comparación de estos métodos no solo permite identificar su eficacia en este contexto, sino que también aporta valor al explorar enfoques personalizados que pueden optimizar la toma de decisiones en el ámbito financiero.

Esta propuesta se justifica en la necesidad de abordar la volatilidad y las irregularidades en las series financieras del sector hondureño, considerando la importancia de estos datos en la planificación económica y el diseño de políticas financieras. Además, contribuye al desarrollo académico y técnico al integrar y evaluar herramientas estadísticas avanzadas en un entorno real y relevante, con ello, se busca no solo mejorar el análisis financiero, sino también proporcionar una base metodológica sólida para futuras investigaciones y aplicaciones en el sector.

6.3 ALCANCE DE LA PROPUESTA

El alcance de este proyecto tiene como objetivo implementar y evaluar métodos de suavizados en el análisis de variables financieras en el sector financiero hondureño. El alcance de esta propuesta se enmarca específicamente en el contexto de la Comisión Nacional de Bancos y Seguros (CNBS), dirigido a las áreas interesadas en el análisis de series temporales con alta volatilidad o ruido. Se espera que la metodología planteada sirva como base para futuras investigaciones en este campo.

6.3.1 OBJETIVO GENERAL DEL PROYECTO

- Incorporación de técnicas de suavizado, como el filtro de Savitzky-Golay y el filtro desarrollado por el DEI, en los análisis de variables financieras para optimizar la calidad de las predicciones y la interpretabilidad de las series temporales financieras.

6.3.2 OBJETIVO ESPECÍFICOS DEL PROYECTO

- Crear una ficha técnica que muestre la metodología y los resultados para que puedan ser utilizados por otras áreas interesados al interno de la CNBS, asegurando que la metodología sea transferibles y replicada dentro de la institución.

- Proponer un cronograma de tareas que establezca el orden de la implementación de la metodología.
- Establecer el presupuesto necesario para la implementación de la metodología.

6.4 DESCRIPCIÓN Y DESARROLLO

6.4.1 DESCRIPCIÓN

La propuesta del proyecto se centra en implementar una metodología para suavizar series temporales afectadas por volatilidad y ruido. El estudio plantea el uso del filtro de Savitzky-Golay y un filtro desarrollado por el Departamento de Estadística e Investigación (DEI), ambos diseñados para reducir el ruido en los datos mientras preservan las características esenciales de las series, esto no solo mejora la calidad y la interpretación de los datos, sino también incrementa la precisión de las predicciones generadas.

En la fase inicial, se llevará a cabo la recopilación de datos esenciales que presenten un alto nivel de ruido y volatilidad. Estas series provienen del sector financiero y corresponden a instituciones que reportan cifras a la Comisión Nacional de Bancos y Seguros. La selección de datos se centrará en aquellas variables que cumplen con las características previamente mencionadas, abarcando el periodo comprendido entre el 31 de enero de 2017 y el 30 de septiembre de 2024. La información recopilada incluye datos sobre la cartera de préstamos, los saldos de depósitos y las transacciones de depósitos, para representar cada conjunto de datos, se seleccionará una institución financiera específica como caso de estudio.

Una vez definidas las variables, se llevará a cabo un proceso de limpieza y depuración de los datos. Este procedimiento se enfocará en eliminar aquellas variables que no presenten un nivel significativo de ruido y volatilidad. El objetivo de esta etapa es garantizar que los datos seleccionados permitan abordar de manera precisa los objetivos planteados en la propuesta.

La implementación de la metodología se llevará a cabo utilizando Excel para el análisis exploratorio de los datos, esta implementación busca comprender la posición de la institución en comparación a las demás instituciones en su entorno financiero y la aplicación de los filtros propuestos, sus métricas para su evaluación se realizarán en Python con un entorno interactivo en Jupyter Notebook, lo que facilita el análisis y la reproducibilidad del proceso. Los resultados se

presentarán en tablas y gráficos que ayuden a visualizar los resultados obtenidos aplicando la metodología.

6.4.1.1 VALIDACIÓN CRUZADA DE LOS MODELOS PREDICTIVOS

La validación cruzada en modelos predictivos para series de tiempo implica evaluar la capacidad del modelo para generalizar sus predicciones a datos no observados. En el contexto que se trabajan con series financieras del sector hondureño que presentan alta volatilidad y ruido, la validación cruzada adquiere particular relevancia debido a la naturaleza no estacionaria de los datos.

División temporal de los datos: Las series de temporales requieren una validación cruzada que respete la secuencia cronológica de los eventos. En este caso, la serie se dividió en un conjunto de entrenamiento que abarca desde enero de 2017 hasta septiembre de 2023.

Prueba del Modelo: Esta etapa se realizará utilizando un conjunto de prueba que comprende de 12 meses, iniciando desde octubre 2023 hasta septiembre de 2024, que garantiza que las predicciones puedan ser comparables con datos pasados y así evaluar su precisión.




Figura 52. Selección del conjunto de entrenamiento y de prueba

Fuente: (Elaboración Propia, 2024)

Evaluación del modelo: La evaluación de los modelos predictivos es la etapa final donde se evalúa el rendimiento del modelo mediante la comparación de las predicciones generadas por el modelo con el conjunto de prueba que comprende de 12 meses. Para el proceso de evaluación se harán uso de métricas claves como el error cuadrático medio (MSE), raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE).

Dado que el estudio incluye variables con ruido y alta volatilidad, el uso de filtros como el de Savitzky-Golay y el desarrollado por el DEI antes del entrenamiento puede mejorar la calidad de las predicciones, lo que también es parte del análisis comparativo. La validación cruzada ayuda

a verificar que el modelo sea capaz de manejar adecuadamente la variabilidad intrínseca de los datos financieros.

6.4.2 DESARROLLO

El proceso de desarrollo de los modelos predictivos para evaluar el rendimiento de los filtros de Savitzky-Golay y el desarrollado por el DEI se llevará a cabo bajo unas series de procesos. La herramienta principal para la extracción de la muestra y procesamiento de los datos se realizará con Excel, posteriormente se utilizará la herramienta de Python con un entorno interactivo en Jupyter Notebook para el desarrollo e implementación de la metodología planteada. Para la visualización de los resultados de los análisis exploratorios se realizarán con la herramienta de Excel y para la implementación de los filtrados se usará la librería de “matplotlib” y el sub módulo llamado “pyplot” que es un interfaz que realiza gráficos en Python.

6.4.2.1 EXTRACCIÓN Y CONSTRUCCIÓN DE LAS VARIABLES

En esta etapa, se realizó la extracción de datos relevantes provenientes de las series temporales seleccionadas. Posteriormente, se llevó a cabo la construcción y transformación de las variables, asegurando que cumplieran con las características requeridas para el análisis, como alta volatilidad y ruido.

En el contexto de una serie temporal, las variables independientes y dependientes se interpretan de manera distinta en comparación con otros tipos de análisis estadísticos, ya que los datos están organizados cronológicamente en función del tiempo. La variable independiente en una serie temporal es el tiempo o los intervalos temporales en los que se registran las observaciones, como meses, años, días u otras unidades temporales relevantes. Por su parte, la variable dependiente es el valor observado en cada punto temporal, el cual representa la magnitud que varía a lo largo del tiempo.

Tabla 19. Selección de variables independiente y dependiente

Variables		Explicación
Independientes	Dependientes	
ene-2017	Cartera Préstamos BANHCAFE Microcréditos	Contiene la serie temporal de los saldos de préstamos del tipo de crédito Microcrédito de la institución BANHCAFE.

	Cartera Préstamos PROMERICA Destino: Industrial	Contiene la serie temporal de los saldos de préstamos del destino de crédito Industrial de la institución PROMERICA.
	Saldo Depósitos LAFISE	Contiene la serie temporal de los saldos de depósitos de la institución LAFISE
sep-2024	Transacciones de Depósitos HONDURAS	Contiene la serie temporal del número de transacciones de Depósitos de la institución HONDURAS

Fuente: (Elaboración Propia, 2024)

6.4.2.2 APLICACIÓN DE LOS FILTROS

Con los datos preparados y extraídos, el siguiente paso es la aplicación de los filtros Savitzky-Golay y el desarrollado por el DEI, el cual se desarrolló con la herramienta de Python y el entorno Jupyter con la ayuda de la librería “Scipy”, esta librería contiene la función del filtro de Savitzky-Golay, por otra parte para aplicar el filtro desarrollado por el DEI se creó un función acorde a la metodología matemática que se me muestra en el Anexo 2, la cual realiza un ajuste con polinomios locales, los pasos son los siguientes:

- En primer lugar, se carga el archivo que contiene los datos a los cuales queremos aplicar los filtros.
- Segundo, se aplica el filtro de Savitzky-Golay a cada uno de las variables que tomó como muestra.
- Tercero, se creó una función que realice gráficos que comparen la serie temporal original y la serie con el filtro, además, se grafican la distribución empírica y teórica de los residuos.
- Cuarto, se creó una función que contiene el algoritmo matemático para aplicar el filtro desarrollado por el DEI a cada variable que se tomó como muestra.

```

import numpy as np
import scipy.stats as stats
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
import re
from scipy.signal import savgol_filter

archivo = 'Data Tesis.xlsx'
xls = pd.ExcelFile(archivo)
cartera_df = pd.read_excel(xls, sheet_name='Cartera')
depositos_df = pd.read_excel(xls, sheet_name='Depositos')
transacciones_df = pd.read_excel(xls, sheet_name='TransaccionesDepositos')

cartera_df['FECHA'] = pd.to_datetime(cartera_df['FECHA'])
cartera_df.set_index('FECHA', inplace=True)
depositos_df['FECHA'] = pd.to_datetime(depositos_df['FECHA'])
depositos_df.set_index('FECHA', inplace=True)
transacciones_df['FECHA'] = pd.to_datetime(transacciones_df['FECHA'])
transacciones_df.set_index('FECHA', inplace=True)

cartera_df['PROMERICA_filtroSG'] = savgol_filter(cartera_df['PROMERICA (Destino:Industria)'],13,5)
cartera_df['BANHCAFE_filtroSG'] = savgol_filter(cartera_df['BANHCAFE (Microcréditos)'],13,5)
depositos_df['BANRURAL_filtroSG'] = savgol_filter(depositos_df['BANRURAL'],13,5)
depositos_df['LAFISE_filtroSG'] = savgol_filter(depositos_df['LAFISE'],13,5)
transacciones_df['BANCATLAN_filtroSG'] = savgol_filter(transacciones_df['BANCATLAN'],13,5)
transacciones_df['HONDURAS_filtroSG'] = savgol_filter(transacciones_df['HONDURAS'],13,5)
transacciones_df['PROMERICA_filtroSG'] = savgol_filter(transacciones_df['PROMERICA'],13,5)

```

Figura 53. Código: Carga de los datos y aplicación del filtro de Savitzky-Golay

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

```

#Graficos
def plot_Residuos(datos, datos_f, titulo, xlabel, ylabel):
    filename = re.sub(r'^A-Za-z0-9+', '_', titulo) + 'DEI.png'
    residuos = datos - datos_f
    fig, ax = plt.subplots(1, 2, figsize=(12, 5))
    ax[0].plot(datos.index, datos, label='Serie Original', color='blue')
    ax[0].plot(datos_f.index, datos_f, label='Serie Filtrada', color='red', linestyle='--')
    ax[0].set_title(titulo)
    ax[0].set_xlabel(xlabel)
    ax[0].set_ylabel(ylabel)
    ax[0].legend()
    # Histograma de Los residuos (distribución empírica)
    ax[1].hist(residuos, bins=20, color='gray', alpha=0.7, density=True, label='Distribución Empírica')
    sns.kdeplot(residuos, color='blue', ax=ax[1], label='Curva de Densidad')
    ax[1].set_title('Distribución Empírica de los Residuos')
    ax[1].set_xlabel('Residuos')
    ax[1].set_ylabel('Densidad')
    # Ajustar una distribución normal a Los residuos (distribución teórica)
    mu, std = stats.norm.fit(residuos)
    xmin, xmax = ax[1].get_xlim()
    x = np.linspace(xmin, xmax, 100)
    p = stats.norm.pdf(x, mu, std)

    # Graficar la distribución teórica normal
    ax[1].plot(x, p, 'r', linewidth=2, label=f'Distribución Teórica (Normal)')
    ax[1].legend()

    plt.tight_layout()
    #plt.savefig(filename, dpi=600)
    plt.show()

```

Figura 54. Código: Función para generar los gráficos de los filtros y residuos.

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

```

from numpy import vander, zeros, linspace, sin, pi
from scipy.linalg import pinv, circulant
from matplotlib.pyplot import spy, plot
from numpy.random import randn
def Phi(s,ws,deg):
    m = int((ws-1)/2)
    x_m = linspace(-m,m,ws)
    J = vander(x_m,deg+1)
    Pw = J@pinv(J.T@J)@J.T
    ls = len(s)
    s_f = zeros(ls)
    for j in range(m):
        s_f[j] = Pw[j,:]*s[:ws]
        s_f[-(j+1)] = Pw[-(j+1),:]*s[-ws:]
    for k in range(ls-ws+1):
        s_f[k+m]=Pw[m,:]*s[(k):(k+ws)]
    return s_f
cartera_df['PROMERICA_filtroDEI'] = Phi(cartera_df['PROMERICA (Destino:Industria)'].values,13,5)
cartera_df['BANHCAFE_filtroDEI'] = Phi(cartera_df['BANHCAFE (Microcréditos)'].values,13,5)
depositos_df['BANRURAL_filtroDEI'] = Phi(depositos_df['BANRURAL'].values,13,5)
depositos_df['LAFISE_filtroDEI'] = Phi(depositos_df['LAFISE'].values,13,5)
transacciones_df['BANCATLAN_filtroDEI'] = Phi(transacciones_df['BANCATLAN'].values,13,5)
transacciones_df['HONDURAS_filtroDEI'] = Phi(transacciones_df['HONDURAS'].values,13,5)
transacciones_df['PROMERICA_filtroDEI'] = Phi(transacciones_df['PROMERICA'].values,13,5)

```

Figura 55. Código: Función que realiza el filtro desarrollado por el DEI.

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

6.4.2.3 DESCOMPOSICIÓN DE SERIES TEMPORALES

La descomposición de las series temporales es un método que nos permite desglosar una serie en sus componentes principales para analizar su comportamiento subyacente. Este enfoque facilita la identificación de patrones, la dirección de la serie si es creciente, decreciente o estable (tendencia), si los patrones tienen un comportamiento cíclico que se repiten regularmente dentro de intervalos de tiempo específicos (estacionalidad) y evalúa el componente aleatorio que no puede ser explicado por la tendencia ni la estacionalidad (residuo o ruido).

Para el análisis de la descomposición de series temporales de las variables de estudio se implementó en Python en el entorno de Jupyter Notebook y se utilizó un enfoque aditivo.

```

import statsmodels.api as sm
import matplotlib.pyplot as plt
import numpy as np

def dst(df1, df2, df3, frecuencia='M', modelo='additive'):
    name1 = df1.name
    name2 = df2.name
    name3 = df3.name
    df1 = df1.asfreq(frecuencia)
    df2 = df2.asfreq(frecuencia)
    df3 = df3.asfreq(frecuencia)
    descomposicion1 = sm.tsa.seasonal_decompose(df1, model=modelo)
    descomposicion2 = sm.tsa.seasonal_decompose(df2, model=modelo)
    descomposicion3 = sm.tsa.seasonal_decompose(df3, model=modelo)
    fig, axes = plt.subplots(4, 3, figsize=(14, 8), sharex=True)
    #fig.suptitle('Descomposición Estacional de Las Series', fontsize=24)
    # Series observadas
    axes[0, 0].plot(descomposicion1.observed, color='blue')
    axes[0, 0].set_title(f"Observado - {name1}")
    axes[0, 1].plot(descomposicion2.observed, color='green')
    axes[0, 1].set_title(f"Observado - {name2}")
    axes[0, 2].plot(descomposicion3.observed, color='red')
    axes[0, 2].set_title(f"Observado - {name3}")
    # Tendencias
    axes[1, 0].plot(descomposicion1.trend, color='blue')
    axes[1, 0].set_title("Tendencia")
    axes[1, 1].plot(descomposicion2.trend, color='green')
    axes[1, 1].set_title("Tendencia")
    axes[1, 2].plot(descomposicion3.trend, color='red')
    axes[1, 2].set_title("Tendencia")
    # Estacionalidad
    axes[2, 0].plot(descomposicion1.seasonal, color='blue')
    axes[2, 0].set_title("Estacionalidad")
    axes[2, 1].plot(descomposicion2.seasonal, color='green')
    axes[2, 1].set_title("Estacionalidad")
    axes[2, 2].plot(descomposicion3.seasonal, color='red')
    axes[2, 2].set_title("Estacionalidad")
    # Residuos
    axes[3, 0].plot(descomposicion1.resid, color='blue')
    axes[3, 0].set_title("Residuos")
    axes[3, 1].plot(descomposicion2.resid, color='green')
    axes[3, 1].set_title("Residuos")
    axes[3, 2].plot(descomposicion3.resid, color='red')
    axes[3, 2].set_title("Residuos")
    plt.tight_layout(rect=[0, 0.03, 1, 0.95])
    filename1 = re.sub(r'^A-Za-z0-9+', '_', f"Descomposicion_{name1}") + '.png'
    #plt.savefig(filename1, dpi=600)
    plt.show()
    residuos1 = descomposicion1.resid
    varianza_residuos1 = round(residuos1.var() / 100000000, 3)
    residuos2 = descomposicion2.resid
    varianza_residuos2 = round(residuos2.var() / 100000000, 3)
    residuos3 = descomposicion3.resid
    varianza_residuos3 = round(residuos3.var() / 100000000, 3)
    print(f"Varianza de los residuos - {name1}: ", varianza_residuos1)
    print(f"Varianza de los residuos - {name2}: ", varianza_residuos2)
    print(f"Varianza de los residuos - {name3}: ", varianza_residuos3)
    if varianza_residuos1 < varianza_residuos2 and varianza_residuos1 < varianza_residuos3:
        mejor_residuo = name1
    elif varianza_residuos2 < varianza_residuos3:
        mejor_residuo = name2
    else:
        mejor_residuo = name3
    print(f"La varianza más pequeña es de: {mejor_residuo}")
    return varianza_residuos1, varianza_residuos2, varianza_residuos3

```

Figura 56. Código: Función que realiza la descomposición de series temporales

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

6.4.2.4 ENTRENAMIENTO DEL MODELO AUTO REGRESIVO (AR)

Para el entrenamiento del modelo auto regresivo (AR), se realizó para una predicción de una ventana de 12 meses, para ello se dividió en un conjunto de entrenamiento y otro de prueba como se explicó anteriormente. Este proceso se realizó en el entorno de Jupyter Notebook con la ayuda de la librería “Statsmodels” para realizar el modelo auto regresivo y la librería “Scikit-Learn” para calcular las métricas de evaluación del modelo.

```
import pandas as pd
from statsmodels.tsa.ar_model import AutoReg
from sklearn.metrics import mean_squared_error, mean_absolute_error
import numpy as np
import re
import matplotlib.pyplot as plt
def comparar_modelos_AR(df, dO, dP, lags=12):
    nombre_dF = df.name
    nombre_dO = dO.name
    nombre_dP = dP.name
    trainF = df[:-12]
    testF = df[-12:]
    trainO = dO[:-12]
    testO = dO[-12:]
    trainP = dP[:-12]
    testP = dP[-12:]
    modF = AutoReg(trainF, lags=lags)
    modF_fit = modF.fit()
    modO = AutoReg(trainO, lags=lags)
    modO_fit = modO.fit()
    modP = AutoReg(trainP, lags=lags)
    modP_fit = modP.fit()
    predF = modF_fit.predict(start=len(trainF), end=len(trainF) + len(testF) - 1, dynamic=False)
    predO = modO_fit.predict(start=len(trainO), end=len(trainO) + len(testO) - 1, dynamic=False)
    predP = modP_fit.predict(start=len(trainP), end=len(trainP) + len(testP) - 1, dynamic=False)
    mseF = mean_squared_error(testF, predF)
    maeF = mean_absolute_error(testF, predF)
    rmseF = np.sqrt(mseF)
    mseO = mean_squared_error(testO, predO)
    maeO = mean_absolute_error(testO, predO)
    rmseO = np.sqrt(mseO)
    mseP = mean_squared_error(testP, predP)
    maeP = mean_absolute_error(testP, predP)
    rmseP = np.sqrt(mseP)
    plt.figure(figsize=(10,6))
    plt.plot(testO.index, testO, label='Valores sin Filtro', color='blue')
    plt.plot(testO.index, predO, label='Predicciones sin Filtro', linestyle='--', color='cyan')
    plt.plot(testF.index, predF, label='Predicciones con Filtro DEI', linestyle='--', color='lime')
    plt.plot(testP.index, predP, label='Predicciones con Filtro SG', linestyle='--', color='gold')
    #plt.title(f"Comparación de Predicciones: Serie de Tiempo {nombre_dO}")
    plt.xlabel('Fecha')
    plt.ylabel('Valor')
    plt.legend()
    filename = re.sub(r'^[A-Za-z0-9]+', '_', f"AR_{nombre_dO}_vs_{nombre_dF}_vs_{nombre_dP}") + '.png'
    #plt.savefig(filename, dpi=600)
    plt.show()
    resultados = pd.DataFrame({
        'Métricas': ['MSE', 'RMSE', 'MAE'],
        nombre_dO: [mseO, rmseO, maeO],
        nombre_dF: [mseF, rmseF, maeF],
        nombre_dP: [mseP, rmseP, maeP]
    })
    print(resultados.to_string(index=False))
```

Figura 57. Código: Función del modelo AR

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

6.4.2.5 ENTRENAMIENTO DEL MODELO AUTORREGRESIVO INTEGRADO DE MEDIA MÓVIL (ARIMA)

Al igual que el modelo auto regresivo (AR) se realizó para una predicción de 12 meses y se dividió la data en un conjunto de entrenamiento y un conjunto de prueba. Este proceso se realizó en el entorno de Jupyter Notebook con la ayuda de la librería “Statsmodels” para realizar el modelo auto regresivo y la librería “Scikit-Learn” para calcular las métricas de evaluación del modelo.

```
import numpy as np
import pandas as pd
import pmdarima as pm
import matplotlib.pyplot as plt
from statsmodels.tsa.arima.model import ARIMA
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from sklearn.metrics import mean_absolute_error, mean_squared_error, mean_absolute_percentage_error
def arima(dei,dsg,do,orden, k=12):
    nf = dei.name
    no = dsg.name
    nt = do.name
    dates = do.index
    data = dei.values
    data2 = dsg.values
    data3= do.values
    train_datadei = data[:-k]
    train_datasg = data2[:-k]
    train_dataor = data3[:-k]
    real_data = data3[-k:]
    train_dates = dates[:-k]
    test_dates = dates[-k:]
    modelf = ARIMA(train_datadei, order=orden)
    modelo = ARIMA(train_datasg, order=orden)
    modelv = ARIMA(train_dataor, order=orden)
    arima_resultf = modelf.fit()
    arima_resulto = modelo.fit()
    arima_resultv = modelv.fit()
    forecastf = arima_resultf.forecast(steps=k)
    forecasto = arima_resulto.forecast(steps=k)
    forecastv = arima_resultv.forecast(steps=k)
    metrics = {}
    for name, forecast in zip([nf, no, nt], [forecastf, forecasto, forecastv]):
        mae = mean_absolute_error(real_data, forecast)
        mse = mean_squared_error(real_data, forecast)
        rmse = np.sqrt(mse)
        mape = mean_absolute_percentage_error(real_data, forecast)

        metrics[name] = {
            'MAE': mae,
            'MSE': mse,
            'RMSE': rmse,
            'MAPE': mape
        }
    best_metrics = {metric: min(metrics, key=lambda x: metrics[x][metric]) for metric in ['MAE', 'MSE', 'RMSE', 'MAPE']}

    plt.plot(test_dates, forecastf, label=f"Proyecciones ARIMA - {nf}", linestyle='--')
    plt.plot(test_dates, forecasto, label=f"Proyecciones ARIMA - {no}", linestyle='--')
    plt.plot(test_dates, forecastv, label=f"Proyecciones ARIMA - {nt}", linestyle='--')
    plt.plot(test_dates, real_data, label=f"Datos Reales (Test) - {nt}")
    plt.legend(fontsize=8)
    #plt.title(f"Comparación de ARIMA {nf}, {no} y {nt} ")
    plt.xlabel('Meses')
    plt.ylabel('Valor')
    filename = re.sub(r'^A-Za-z0-9+', '_', f"ARIMA_{nt}_vs_{no}_vs_{nf}") + '.png'
    plt.savefig(filename, dpi=600)
    plt.show()
```

Figura 58. Código: Función del modelo ARIMA

Fuente: (Elaboración Propia Jupyter Notebook, 2024)

6.5 MEDIDAS DE CONTROL

Con el objetivo de verificar la eficacia de los filtros en la reducción del ruido y la mejora de la interpretabilidad de las series temporales, se llevó a cabo un análisis exhaustivo utilizando diversos métodos y métricas. Este análisis busca optimizar la precisión de las predicciones y comparar el desempeño de los filtros aplicados en términos de su impacto en las series analizadas.

El estudio incluyó una comparación detallada utilizando métricas claves, como el error cuadrático medio, la raíz del error cuadrático medio, error absoluto medio y la varianza de los residuos. Estas métricas permiten medir cuantitativamente la efectividad de los filtros en la mejora de las predicciones, así como la reducción del ruido residual presente de las series.

Adicionalmente, se incorporó una evaluación visual mediante gráficos que comparan las series originales con las series filtradas, que permitió observar de manera clara los cambios en la suavidad y la identificación de patrones tras la aplicación de cada filtro. Asimismo, las pruebas se realizaron en diferentes variables financieras para evaluar la robustez de los filtros en escenarios con distintos niveles de ruido y volatilidad.

El análisis comparativo se enfocó en los filtros de Savitzky-Golay y el desarrollado por el DEI. Además de considerar su capacidad para reducir el ruido, se evaluó su impacto en la estabilidad y precisión de los modelos AR y ARIMA. Este enfoque integral garantiza que los resultados obtenidos sean representativos y útiles para aplicaciones futuras en el análisis de series temporales, contribuyendo al fortalecimiento de las herramientas analíticas en la CNBS.

Tabla 20. Métricas de evaluación del modelo AR

Serie Temporal	Detalle	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
BANHCAFE Microcréditos	Filtro DEI	9,792	3,129	2,947
	Original	29,175	5,401	4,187
	Filtro Savitzky-Golay	57,228	7,565	6,918
PROMERICA Destino: Industrial	Filtro DEI	3,187	1,785	1,466
	Filtro Savitzky-Golay	6,312	2,512	1,827
	Original	12,578	3,546	2,642
LAFISE Saldo Depósitos	Filtro DEI	22,110,153	148,695	117,262
	Original	30,667,019	175,120	148,293
	Filtro Savitzky-Golay	317,299,985	563,294	516,352
Honduras Transacciones de Depósitos	Filtro DEI	14,326	3,784.9	3,217.5
	Filtro Savitzky-Golay	103,972	10,196.7	8,479.4
	Original	124,772	11,170.1	7,737.8

Fuente: (Elaboración Propia, 2024)

Tabla 21. Métricas de evaluación del modelo ARIMA

Serie Temporal	Detalle	Error Cuadrático Medio	Raíz del Error Cuadrático	Error Absoluto Medio
BANHCAFE Microcréditos	Filtro DEI	2,526	1,589	1,213
	Original	11,848	3,442	2,824
	Filtro Savitzky-Golay	13,354	3,654	3,284
PROMERICA Destino: Industrial	Filtro Savitzky-Golay	944	972	858
	Filtro DEI	6,118	2,473	2,029
	Original	606,767	24,633	22,261
LAFISE Saldo Depósitos	Filtro DEI	11,598,613	107,697	94,154
	Original	94,736,228	307,793	270,882
	Filtro Savitzky-Golay	95,750,587	309,436	255,176
Honduras Transacciones de Depósitos	Filtro Savitzky-Golay	32,489	5,699.9	3,912.9
	Filtro DEI	37,928	6,158.6	4,832.3
	Original	38,874	6,234.9	5,239.0

Fuente: (Elaboración Propia, 2024)

6.6 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

La planificación adecuada de un proyecto requiere definir tanto el cronograma de actividades como el presupuesto necesario para garantizar el cumplimiento de los objetivos en los plazos establecidos. Este apartado busca detallar las etapas claves de la implementación y los recursos financieros requeridos, para lograr resultados exitosos alineados con los objetivos específicos de la propuesta de aplicabilidad.

A lo largo del tiempo se han desarrollado técnicas para la estimación de tiempos, con el objetivo de mejorar la planificación, control y ejecución de proyectos. Para establecer una ruta crítica clara del cronograma de implementación y presupuestos haremos uso de la técnica PERT (Program Evaluation and Review Technique) y el gráfico de Gantt.

6.6.1 TÉCNICA PERT (PROGRAM EVALUATION AND REVIEW TECHNIQUE)

La técnica PERT es una herramienta eficaz para la planificación y gestión de proyectos que involucran múltiples tareas interdependientes. Esta metodología se utiliza para calcular el tiempo estimado de finalización de un proyecto mediante la identificación de rutas críticas y el análisis de actividades clave, permite identificar posibles retrasos y ajustar recursos

estratégicamente, optimizando la eficiencia y reduciendo riesgos.

El desarrollo del método PERT se inició en 1957 cuando la Marina de los Estados Unidos se enfrentó a la problemática de coordinación y control que surgió en la realización del proyecto de submarinos atómicos armados con proyectiles Polaris. (Cuervo García, 1977).

El método PERT considera tres estimaciones de tiempo para cada actividad:

1. Tiempo ideal (x): Es la duración de la actividad bajo condiciones óptimas, cuando todo se desarrolla sin contratiempos, corresponde al tiempo más corto en que una actividad.
2. Tiempo más frecuente (m): Es el tiempo estimado cuando el desarrollo de la actividad ocurre de manera normal, se toma como referencia el tiempo promedio o más comúnmente observado para actividades similares.
3. Tiempo desfavorable (y): Es la duración de la actividad en circunstancias adversas, cuando surgen dificultades, este tiempo refleja el escenario más negativo posible.

Para una determinada actividad j , utilizando las tres estimaciones anteriores para determinar el tiempo estimado T , su cálculo es el siguiente:

$$T_j = \frac{x + 4m + y}{6}$$

6.6.2 ANÁLISIS DE DIAGRAMAS DE GANTT

Los diagramas de Gantt son una representación visual del cronograma del proyecto, mostrando las tareas, sus duraciones y las relaciones entre ellas. Este diagrama es útil para realizar un seguimiento detallado del estado de cada actividad y asegurar que se respeten los plazos previstos.

6.6.3 DESARROLLO DEL CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO

El cronograma de implementación y presupuesto lo haremos en dos fases:

6.6.3.1 FICHA TÉCNICA

El cronograma de implementación y presupuesto de la realización de la ficha técnica que muestre la metodología y los resultados para que puedan ser utilizados por otras áreas interesadas al interno de la CNBS. La estimación de los tiempos según la técnica PERT se muestra en la siguiente tabla:

Tabla 22. Estimaciones de Tiempo PERT: Ficha Técnica

Actividad a desarrollar	<i>x</i> (meses)	<i>m</i> (meses)	<i>y</i> (meses)	Tiempo Estimado (<i>T_j</i> , meses)
Ficha Técnica de la Metodología	2	3	5	3.2
Revisión y Publicación	2	3	5	3.2

Fuente: (Elaboración Propia, 2024)

Las estimaciones de los tiempos “*x*, *m*, *y*” en la Tabla 22 se consideran según las experiencias obtenidas en el desarrollo, revisión y publicación de fichas técnicas en las actividades desarrolladas por el Departamento de Estadísticas e Investigación. Además, las actividades involucradas en la implementación están interrelacionadas y siguen una secuencia o regla de precedencia, lo que implica que la ejecución de la primera actividad debe completarse antes de que pueda iniciarse la segunda.

Al aplicar la fórmula de la técnica PERT para estimar el tiempo, los resultados indican que el tiempo estimado para la implementación es de 3.2 meses, lo cual es cercano al tiempo más frecuente (*m*).

A continuación, se presenta el diagrama de Gantt de las actividades necesarias para desarrollar la ficha técnica, el cual está basado en los tiempos estimados mediante la técnica PERT, como se muestra en la siguiente tabla:

Tabla 24. Diagrama de Gantt: Cronograma de Implementación y Presupuesto de la Ficha Técnica

Actividad a desarrollar	Inversión Lps.	Año 2025					
		enero	febrero	marzo	abril	mayo	junio
Ficha Técnica de la Metodología	-						
Revisión y Publicación	-						

Fuente: (Elaboración Propia, 2024)

El cronograma y presupuesto de la Tabla 24 muestra las actividades de realización de la ficha técnica, ambas actividades tienen un presupuesto cero, esto debido a que la realización de la ficha se pretende se lleve a cabo como una actividad por el Departamento de Estadísticas e Investigación de la CNBS, quedando como un insumo interno para que sea utilizado por las áreas que muestren interés en la metodología al interno de la CNBS.

6.6.3.2 IMPLEMENTACIÓN DE LA METODOLOGÍA POR LAS ÁREAS INTERESADAS

En esta fase las actividades incluyen capacitaciones clave en herramientas y conceptos fundamentales, como Python, estadística y álgebra lineal, que son esenciales para garantizar la correcta ejecución y análisis de las series temporales.

Los costos de las capacitaciones se realizaron en base a diplomados y cursos que ofrece la Maestría en Matemáticas y la Facultad de Ciencias de la Universidad Nacional Autónoma de Honduras, entre los cursos que ofrece están los siguientes:

- Cursos Propedéuticos: Algebra Lineal, Principios de Análisis Matemático y Herramientas Computacionales. **Costo Lps.14,400**
- Curso de Python: Entorno IDE, Operadores y tipos dinámicos, Cadenas, Tuplas, listas y diccionarios, Bloques estructurados y funciones, Manipulación de ficheros, Librería Numpy y Scipy, Elaboración de gráficos, Librería Networkx, Librería para un entorno GUI. **Costo Lps.2,000**
- Curso de Introducción a Machine Learning en Python: Sesgo, varianza y sobreajuste, Tipos de aprendizaje (supervisado y no supervisado), Métricas para evaluación de modelos, Librerías de Python para implementar modelos de aprendizaje automático, Herramientas de visualización de datos, Algoritmos de

Clasificación, Regresión logística, K-vecinos más próximos (K-NN), Modelos aditivos y métodos relacionados, Clustering y evaluación de modelos. **Costo Lps.3,000**

- Diplomado de Estadística Aplicada: Estadística Descriptiva y Probabilidad, Elementos de Estadística Inferencial, Regresión lineal simple y múltiple, análisis de varianza, Pruebas de Independencia y muestreo, Proyecto de investigación. **Costo Lps.7,000**

Tabla 25. Costos y Duración de los Cursos Ofrecidos por la UNAH

Actividad a desarrollar	Costos	Duración (Semanas)	Dependencia	Anexos
Cursos Propedéuticos	L 14,400.00	23	Inicio	Ver Anexo 5
Curso de Python	L 2,000.00	4	Inicio	Ver Anexo 6
Curso de Introducción a Machine Learning en Python	L 3,000.00	4	Curso de Python	Ver Anexo 7
Diplomado de Estadística Aplicada	L 7,000.00	23	Inicio	Ver Anexo 8

Las estimaciones de los tiempos “ x , m , y ” en la Tabla 26 se consideran según lo establecido en el desarrollo curricular de cada curso o diplomado que ofrece la Maestría en Matemáticas de la Universidad Nacional Autónoma de Honduras. La estimación de los tiempos según la técnica PERT, se muestra en la siguiente tabla:

Tabla 26. Estimaciones de Tiempo PERT: Implementación por las Áreas Interesadas

Actividad a desarrollar	x (semanas)	m (semanas)	y (semanas)	Tiempo Estimado (T_j , semanas)
Cursos Propedéuticos	20	23	26	23
Curso de Python	3	4	6	4.2
Curso de Introducción a Machine Learning en Python	3	4	6	4.2
Diplomado de Estadística Aplicada	20	23	26	23

El diagrama de Gantt de las actividades necesarias para la implementación de la metodología por las áreas interesadas, el cual está basado en los tiempos estimados mediante la técnica PERT, se muestra en la siguiente tabla:

Tabla 27. Diagrama de Gantt: Cronograma de Implementación y Presupuesto para las Áreas Interesadas

Actividad a desarrollar	Inversión Lps.	Semana																						
		1	2	3	4	5	6	7	8	22	23										
Cursos Propedéuticos	14,400	[Barra azul que cubre las semanas 1 a 23]																						
Curso de Python	2,000	[Barra azul que cubre las semanas 1 a 4]																						
Curso de Introducción a Machine Learning en Python	3,000						[Barra azul que cubre las semanas 6 a 8]																	
Diplomado de Estadística Aplicada	7,000	[Barra azul que cubre las semanas 1 a 23]																						
Inversión Total	26,400																							

Fuente: (Elaboración Propia, 2024)

El cronograma de la Tabla 27 está estructurado en un periodo estimado de ejecución, con una distribución específica de las capacitaciones para optimizar el tiempo y los recursos disponibles, el presupuesto total estimado asciende a L. 26,400, cubriendo las inversiones requeridas para cada actividad. Este plan tiene como objetivo fortalecer las capacidades técnicas del equipo involucrado y asegurar una implementación exitosa de los modelos propuestos por las áreas interesadas a implementar la metodología.

6.7 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

La matriz de concordancia entre los segmentos de la tesis y la propuesta es crucial para evaluar el grado de alineación entre nuestra investigación y los objetivos planteados en la propuesta inicial. Este análisis permite examinar cómo cada sección de la tesis se vincula con la visión original, garantizando consistencia, pertinencia y fidelidad a los enfoques previamente establecidos.

Tabla 28. Matriz de concordancia de los segmentos de la tesis con la propuesta

Capítulo I		Capítulo II	Capítulo III		Capítulo V	Capítulo VI		
Título Investigación	Objetivo General	Objetivo Específicos	Teorías/Metodología de sustento	Variables	Poblaciones	Conclusiones	Nombre de la propuesta	Objetivos propuesta
Análisis de Suavizado de Series Temporales Financieras: Aplicación del Filtro de Savitzky-Golay y Un Filtro Desarrollado Localmente en el Sector Financiero Hondureño	Analizar y mejorar el análisis de series temporales financieras altamente volátiles mediante el uso del filtro de Savitzky-Golay y el filtro desarrollado por Departamento de Estadísticas e Investigación (DEI), con el fin de fortalecer la capacidad de tomar decisiones informadas en entornos financieros dinámicos y complejos.	Evaluar el impacto de los filtros en la reducción de ruido y la preservación de características importantes en series temporales financieras con alta volatilidad.	Análisis de varianza de los residuos. Gráfico de la distribución teórica y empírica de los residuos. Descomposición de Series Temporales.	Variables que dependen del tiempo (indicador financiero a lo largo de una ventana de tiempo)	Sector Financiero Hondureño	La descomposición de series temporales resultó una herramienta clave para analizar y comprender mejor cada componente de las series, este método permite separar las series en sus principales elementos: tendencia, estacionalidad y ruido, lo que facilita su interpretación al proporcionar una visión más clara y estructurada de su comportamiento. La identificación de la tendencia ayuda a reconocer los patrones subyacentes a largo plazo, la estacionalidad destaca los ciclos recurrentes, y el aislamiento del ruido permite enfocarse en los datos relevantes sin distracciones causadas por fluctuaciones aleatorias. Aunque la descomposición de series ofrece una perspectiva detallada y estructurada, no representa una limitación en el análisis de series temporales ya que, además, existen diversas métricas que pueden evaluar la efectividad del uso de filtros en series temporales.	Propuesta para la Implementación de Suavizado de Series Temporales con el Uso del Filtro de Savitzky-Golay y el Filtro Desarrollado por el DEI en Variables Financieras del Sector Hondureño	Incorporación de técnicas de suavizado, como el filtro de Savitzky-Golay y el filtro desarrollado por el DEI, en los análisis de variables financieras para optimizar la calidad de las predicciones y la interpretabilidad de las series temporales financieras.
		Comparar el rendimiento entre los filtros propuestos para el análisis de series en términos de precisión en la detección de tendencias y la predicción de comportamientos futuros en series temporales financieras altamente volátiles.	Análisis de las métricas de los métodos AR y ARIMA para evaluar el impacto del ruido en las predicciones.	Variables que dependen del tiempo con componentes autorregresivas (indicador financiero a lo largo de una ventana de tiempo)		Ya se demostró en los análisis de los resultados que el filtro desarrollado por el DEI superó al filtro de Savitzky-Golay al reducir mejor el ruido latente en la serie de tiempo. En el análisis de descomposición de series temporales se calculó las varianzas de cada serie demostrando que el filtro del DEI es el que reduce significativamente la varianza de los residuos. Para los modelos AR el filtro DEI es el que proporcionó las mejores métricas de las predicciones en las diferentes variables que fueron analizadas, por otra parte, para el modelo ARIMA el filtro de Savitzky-Golay obtuvo buenos rendimientos en las predicciones de las series del banco HONDURAS y PROMERICA.		Crear una ficha técnica que muestre la metodología y los resultados para que puedan ser utilizados por otras áreas interesadas al interno de la CNBS, asegurando que la metodología sea transferibles y replicada dentro de la institución.
								Proponer un cronograma de tareas que establezca el orden de la implementación de la metodología. Establecer el presupuesto necesario para la implementación de la metodología.

		Identificar y optimizar los parámetros de los filtros para maximizar su eficacia en el análisis de series temporales financieras caracterizadas por una alta volatilidad.	Uso de una metodología para determinar el número de ventana y grado de polinomio óptimo.	VARIABLES QUE DEPENDEN DEL TIEMPO (INDICADOR FINANCIERO A LO LARGO DE UNA VENTANA DE TIEMPO)	<p>La configuración óptima de los filtros, en términos del grado del polinomio y el tamaño de la ventana, depende de la naturaleza de los datos y del nivel de suavizado deseado. A medida que se incrementa el grado del polinomio y el tamaño de la ventana, el filtro elimina más eficazmente el ruido, pero también puede suprimir características esenciales que resultan valiosas para realizar predicciones.</p> <p>Dombi y Dineva, (2020), en su estudio sobre el filtrado adaptativo Savitzky-Golay y sus aplicaciones, recomiendan utilizar un grado de polinomio igual a 5 para ventanas de tamaño 11 o mayor. En nuestro análisis, con el objetivo de predecir 12 meses hacia adelante, se decidió emplear una ventana de 13 meses y un grado de polinomio igual a 5, siguiendo las recomendaciones previas. Esta configuración se consideró óptima y se aplicó a cada variable de estudio utilizando tanto el filtro Savitzky-Golay como el filtro desarrollado por el DEI.</p>		
--	--	---	--	--	--	--	--

Fuente: (Elaboración Propia, 2024)

REFERENCIAS BIBLIOGRÁFICAS

- Acerca de - Datos Abiertos. (2024, 4 de noviembre).
<https://datos.cnbs.gob.hn/about>
- Amazon Web Services, Inc. (2024, 22 de febrero). *¿Qué es Python? - Explicación del lenguaje Python - AWS*. <https://aws.amazon.com/es/what-is/python/>
- Ayres, F. (1991). *Cálculo diferencial e integral*. McGraw-Hill.
https://www.cimat.mx/ciencia_para_jovenes/bachillerato/libros/calculo_ayres.pdf
- Baba, K., Bahi, L. y Ouadif, L. (2024, 17 de marzo). *Enhancing Geophysical Signals Through the Use of Savitzky-Golay filtering method*.
<https://www.redalyc.org/articulo.oa?id=56832068003>
- Basel Committee on Banking Supervision (2012). Principios Básicos para una supervisión bancaria eficaz. https://www.bis.org/publ/bcbs230_es.pdf
- Comisión Nacional de Bancos y Seguros. (2024, 5 de marzo). *Acerca de la CNBS - Comisión Nacional de Bancos y Seguros*. <https://www.cnbs.gob.hn/acerca-de-la-cnbs/>
- Cuervo García (1977). PROGRAMACION DE PROYECTOS. ESTUDIO SOBRE EL METODO P.E.R.T. *Revista Española De Financiación Y Contabilidad*, 6(22), 697–726.
<http://www.jstor.org/stable/42781809>
- Dombi, J. y Dineva, A. (2020). Adaptive Savitzky-Golay filtering and its applications. *International Journal of Advanced Intelligence Paradigms*, 16(2), Artículo 107011, 145.
<https://doi.org/10.1504/IJAIP.2020.107011>
- Fernando Moreno Pino (2023). Deep attentive time series modelling for quantitative finance, 1.
<https://dialnet.unirioja.es/servlet/tesis?codigo=321802>
- Filtrar y suavizar datos - MATLAB & Simulink*. (2024, 16 de marzo).
https://www.mathworks.com/help/curvefit/smoothing-data_es.html
- FUENTES, M. (2020). *DINAMICA CIENTIFICA Y MEDIDAS DE COMPLEJIDAD*. SADAF.
- Jonathan D. Cryer Kung-Sik Chan. (2008). *Time Series Analysis: With Applications in R*. University of Iowa. <https://link.springer.com/book/10.1007/978-0-387-75959-3>
- Jongwoo Baik, Jiyoung Choi y Hoekyung Jung (2022). Filtering Correction Method and Performance Comparison for Time Series Data, 20(2), 125–130.
<https://doi.org/10.6109/jicce.2022.20.2.125>
- José Alberto Mauricio (2007, marzo). Análisis de Series Temporales.
https://d1wqtxts1xzle7.cloudfront.net/42396751/518-2013-11-11-JAM-IASST-Libro-libre.pdf?1454960455=&response-content-disposition=inline%3B+filename%3DAnálisis_de_Series_Temporales.pdf&Expires=1710646834&Signature=EcqtBxqJvWgLYNMcrfDDwptqnSDIuleFEgLfef~EeNczO92ZpD-K5wF0aT0T-fCdT1P4qE0HGQrIcKXB-pP4QYLRWXQIDJd4TrXba4MgDWQvYhDDOE12OpBRZJJr~X8d0jnwsRQq93GBImhwnSK8d7jjSxrewyg4fZUsezkdznmhybC0mALcuHutQX9bLgm3FeEYJLLUorckOpvtG1LostF0NILKeX8BpJ9USvI8HT4Gx73qPKbXiknptZjhAdfR4gwh2CP0u2U~u~ksZn90yOrrjGnk6lsbh5L5GT6e278Qn5jTEV1KmUZeUjsnDDjFE20pNMk1COiyH0QWLbJT3Q__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA
- Larive, C. K. y Sweedler, J. V. (2013). Celebrating the 75th anniversary of the ACS Division of Analytical Chemistry: A special collection of the most highly cited analytical chemistry papers published between 1938 and 2012. *Analytical Chemistry*, 85(9), 4201–4202.
<https://doi.org/10.1021/ac401048d>

- Niedźwiecki, M. J., Ciołek, M., Gańcza, A. y Kaczmarek, P. (2021). Application of regularized Savitzky–Golay filters to identification of time-varying systems. *Automatica*, 133. <https://doi.org/10.1016/j.automatica.2021.109865>
- Ortiz Bravo, V. A., Nieto Arias, M. A., & Castañeda Cardenas, J. A. (2013). ANALISIS Y APLICACIÓN DEL FILTRO DE KALMAN A UNA SEÑAL CON RUIDO ALEATORIO. *Scientia Et Technica*, 18(1), 267–274. <https://doi.org/10.22517/23447214.8241>
- Reglamento general de protección de datos (27 de abril de 2016). <http://data.europa.eu/eli/reg/2016/679/oj>
- Savitzky, A [Abraham] (1989). A historic collaboration. *Analytical Chemistry*, 61(15), 921A-923A. <https://doi.org/10.1021/ac00190a003>
- Savitzky, A [Abraham.] y Golay, M. J. E. (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, 36(8), 1627–1639. <https://doi.org/10.1021/ac60214a047>
- Schafer, R. (2011). What Is a Savitzky-Golay Filter? [Lecture Notes]. *IEEE Signal Processing Magazine*, 28(4), 111–117. <https://doi.org/10.1109/msp.2011.941097>
- Sergio Iván Padrón Ortega, Ernestina Elizabeth Banda-Cruz, Nohra Violeta Gallardo-Rivas. (2023). *Aplicación de filtros Savitzky-Golay y transformada rápida de Fourier en el procesamiento de espectros derivados obtenidos a partir de soluciones de asfaltenos*. Tecnológico Nacional de México. CienciaUAT. https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-78582024000100170
- Vicente Chirivella González (2015). Hipótesis en el modelo de regresión lineal por Mínimos Cuadrados Ordinarios. <https://riunet.upv.es/bitstream/handle/10251/53302/Hip%C3%B3tesis%20en%20el%20modelo%20de%20regresi%C3%B3n%20lineal%20por%20M%C3%ADnimos%20Cuadrados%20Ordinarios.pdf>
- Weng, S., Tang, P., Yuan, H., Guo, B., Yu, S., Huang, L. y Xu, C. (2020). Hyperspectral imaging for accurate determination of rice variety using a deep learning network with multi-feature fusion. *Spectrochimica Acta. Part A, Molecular and Biomolecular Spectroscopy*, 234, 118237. <https://doi.org/10.1016/j.saa.2020.118237>
- World Bank. (2011). *Principios Generales para los Sistemas de Información Crediticia del Banco Mundial*. <https://www.worldbank.org/en/publication/gfdr/gfdr-2016/background/credit-registry>

ANEXOS

ANEXO 1: MODELACIÓN MATEMÁTICA DEL FILTRO DE SAVITZKY-GOLAY

Introducción

El objetivo del filtro de Savitzky-Golay es suavizar una señal y_i para obtener una señal suavizada \hat{y}_i . El filtrado se realiza usando un polinomio ajustado en una ventana de datos alrededor de cada punto y_i .

Selección de Parámetros

- **Orden del polinomio:** n (donde n es un número entero que define el grado del polinomio).
- **Tamaño de la ventana:** $2m + 1$ (donde m es el número de puntos a cada lado del punto central).

Ajuste del Polinomio

Para cada ventana de $2m + 1$ puntos, el polinomio de orden n tiene la forma:

$$P(x) = a_0 + a_1 x + a_2 x^2 + \dots + a_n x^n$$

donde a_0, a_1, \dots, a_n son los coeficientes que se deben determinar.

Sistema de Ecuaciones

Se forman las ecuaciones del sistema para minimizar el error cuadrático entre el polinomio y los puntos de la ventana. Se toma la matriz de Vandermonde V :

$$V = \begin{pmatrix} 1 & -m & (-m)^2 & \dots & (-m)^n \\ 1 & -m+1 & (-m+1)^2 & \dots & (-m+1)^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & m & m^2 & \dots & m^n \end{pmatrix}$$

donde cada fila corresponde a un punto de datos en la ventana.

Cálculo de los Coeficientes

El vector de observaciones es $Y = (y_{i-m}, y_{i-m+1}, \dots, y_{i+m})^T$ y el vector de coeficientes es $A = (a_0, a_1, \dots, a_n)^T$.

El sistema de ecuaciones se expresa como:

$$VA = Y$$

Para encontrar A , se puede usar el método de mínimos cuadrados, lo que implica resolver la siguiente ecuación normal:

$$V^T VA = V^T Y$$

Cálculo de Coeficientes de Savitzky-Golay

Al resolver la ecuación anterior, obtenemos los coeficientes A . Sin embargo, para simplificar el cálculo en futuras aplicaciones, los coeficientes de Savitzky-Golay se pueden precalcular y expresar como:

$$C = V^{-1} \cdot \begin{pmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$$

Esto significa que estamos buscando el polinomio que pasa por el punto y_i y no se ajusta a ningún término de orden superior en Y .

Aplicación del Filtro

Finalmente, para obtener la señal suavizada, utilizamos la convolución entre los puntos de la señal y los coeficientes c_j :

$$\hat{y}_i = \sum_{j=-m}^m c_j y_{i+j}$$

Resumiendo el Proceso

1. **Seleccionar** el orden del polinomio n y el tamaño de la ventana $2m + 1$.
2. **Construir** la matriz de Vandermonde V .
3. **Calcular** los coeficientes C usando la inversión de matrices.
4. **Aplicar** la convolución para obtener la señal suavizada \hat{y}_i .

Referencias

1. Wikipedia contributors. (n.d.). Savitzky-Golay filter. In Wikipedia, The Free Encyclopedia. Recuperado el 25 de octubre de 2024, de https://en.wikipedia.org/wiki/Savitzky%E2%80%93Golay_filter
2. MathWorks. (n.d.). Design and analyze Savitzky-Golay filters. Recuperado de <https://www.mathworks.com/help/signal/ug/design-and-analysis-of-savitzky-golay-filters.html>

ANEXO 2: MODELACIÓN MATEMÁTICA DEL FILTRO DESARROLLADO POR EL DEI

Filtrado: Ajuste con Polinomio Local (Departamento de Estadísticas e Investigación, CNBS)

Introducción

Para cada punto de la señal s , se selecciona una ventana de datos de tamaño (ws) y se ajusta un polinomio de grado g a los datos de esa ventana. Este método se basa en la **regresión polinomial ponderada** o ajuste por **mínimos cuadrados locales**, y su objetivo es suavizar la señal preservando sus características globales.

Matriz de diseño

Dada una ventana de tamaño ws centrada en un punto de la señal, los puntos de la ventana están ubicados en posiciones relativas x_m , que varían entre $-m$ y m , donde:

$$m = \frac{ws - 1}{2}$$

Por ejemplo, si $ws = 5$, entonces los puntos $x_m = [-2, -1, 0, 1, 2]$.

La matriz de diseño para ajustar un polinomio de grado deg es una **matriz de Vandermonde**, que tiene la siguiente forma:

$$\mathbf{J} = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^g \\ 1 & x_2 & x_2^2 & \dots & x_2^g \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{ws} & x_{ws}^2 & \dots & x_{ws}^g \end{bmatrix}$$

Esta matriz tiene ws filas y $g + 1$ columnas.

Ajuste por mínimos cuadrados

El ajuste por mínimos cuadrados busca minimizar el error cuadrático entre el polinomio ajustado y los valores de la señal en la ventana. Esto se expresa como:

$$\mathbf{y}_{ws} = \mathbf{J}\boldsymbol{\beta}$$

donde:

- \mathbf{y}_{ws} es el vector de valores de la señal dentro de la ventana (de longitud (ws)).
- $\boldsymbol{\beta}$ es el vector de coeficientes del polinomio (de longitud $g + 1$).

La solución del problema de mínimos cuadrados es:

$$\boldsymbol{\beta} = (\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T \mathbf{y}_{ws}$$

donde $(\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T$ es la pseudo-inversa de la matriz de Vandermonde \mathbf{J} .

Matriz de proyección

En lugar de calcular los coeficientes del polinomio para cada ventana, podemos calcular la **matriz de proyección**:

$$\mathbf{P}_w = \mathbf{J}(\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T$$

Esta matriz proyecta los valores de la señal en la base polinómica de la ventana. Dado un conjunto de valores de la señal \mathbf{y}_{ws} , el valor suavizado en cada punto de la ventana se obtiene como:

$$\mathbf{s}_f = \mathbf{P}_w \mathbf{y}_{ws}$$

Aplicación en cada ventana

El ajuste polinomial aplica este procedimiento a cada punto de la señal:

- En los bordes de la señal (primeros y últimos m puntos), ajusta usando solo una parte de la ventana.
- Para los puntos internos, utiliza una ventana completa de tamaño w_s .

Para los bordes, ajusta los primeros m puntos de la señal:

$$s_f[j] = \mathbf{P}_w[j, :] \cdot \mathbf{y}_{1:w_s}$$

y ajusta los últimos m puntos usando:

$$s_f[-j] = \mathbf{P}_w[-j, :] \cdot \mathbf{y}_{-w_s:}$$

Para los puntos internos, el valor suavizado en el punto $k + m$ se obtiene usando una ventana centrada en dicho punto:

$$s_f[k + m] = \mathbf{P}_w[m + 1, :] \cdot \mathbf{y}_{k:k+w_s}$$

Conclusión

El resultado final es una señal suavizada s_f , donde cada punto es el resultado de ajustar un polinomio local a los puntos de la señal dentro de una ventana centrada en dicho punto.

Referencia

1. Vides, F. Lopez, G. Structured Reservoir Computing Circuits for System Identification. Technical report. In preparation.

ANEXO 3: FUNCIÓN PARA COMPROBAR ESTACIONALIDAD (PRUEBA DE DICKY-FULLER)

```
def estacionario(dO, dSG, dDEI):
    from statsmodels.tsa.stattools import adfuller
    import numpy as np

    def make_stationary(data, column_name):
        diff_count = 0
        while True:
            adf_result = adfuller(data)
            if adf_result[1] < 0.05: # La serie es estacionaria si p-valor < 0.05
                print(f"La serie '{column_name}' es estacionaria tras {diff_count} diferenciación(es).")
                return data
            else:
                data = np.diff(data) # Aplica diferenciación
                diff_count += 1
                print(f"Diferenciación aplicada a '{column_name}': {diff_count}")

    # Obtén los nombres de las columnas y los datos
    nO = dO.name
    dataO = dO.values
    nSG = dSG.name
    dataSG = dSG.values
    nDEI = dDEI.name
    dataDEI = dDEI.values

    # Verifica y transforma a estacionaria cada serie
    dataO = make_stationary(dataO, nO)
    dataSG = make_stationary(dataSG, nSG)
    dataDEI = make_stationary(dataDEI, nDEI)
```

ANEXO 4: FUNCIÓN PARA GENERAR GRÁFICOS ACF Y PACF

```
import matplotlib.pyplot as plt
import pandas as pd
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf

def grafico_acf_pacf(dO, dSG, dDEI, dif1):
    # Inicializar Los nombres de las series
    name1 = dO.name
    name2 = dSG.name
    name3 = dDEI.name

    # Crear DataFrames de las series
    series = [dO, dSG, dDEI]
    names = [name1, name2, name3]

    # Crear la figura y los subgráficos
    fig, axes = plt.subplots(3, 2, figsize=(12, 12))

    # Iterar sobre las series para procesarlas y graficarlas
    for i, serie in enumerate(series):
        # Crear DataFrame para cada serie
        df = pd.DataFrame({names[i]: serie})

        if dif1 == 1:
            # Realizar la primera diferencia y la diferencia estacional
            df['Primera Diferencia'] = df[names[i]] - df[names[i]].shift(1)
            df['Diferencia Estacionalidad'] = df['Primera Diferencia'] - df['Primera Diferencia'].shift(12)
        else:
            # Realizar la primera y segunda diferencia y la diferencia estacional
            df['Primera Diferencia'] = df[names[i]] - df[names[i]].shift(1)
            df['Segunda Diferencia'] = df['Primera Diferencia'] - df['Primera Diferencia'].shift(1)
            df['Diferencia Estacionalidad'] = df['Segunda Diferencia'] - df['Segunda Diferencia'].shift(12)


        # Dividir en entrenamiento y prueba
        df_train = df[:-12]
        df_test = df[-12:]

        # Graficar ACF y PACF en el mismo conjunto de subgráficos
        plot_acf(df_train['Diferencia Estacionalidad'].dropna(), lags=24, ax=axes[i, 0])
        plot_pacf(df_train['Diferencia Estacionalidad'].dropna(), lags=24, ax=axes[i, 1])

        # Establecer los títulos
        axes[i, 0].set_title(f'ACF {names[i]}')
        axes[i, 1].set_title(f'PACF {names[i]}')

    # Ajustar el diseño para evitar superposición
    plt.tight_layout()
    filename = re.sub(r'^A-Za-z0-9+', '_', f"ACFyPACF_{name1}_vs_{name2}_vs_{name3}") + '.png'
    #plt.savefig(filename, dpi=600)
    plt.show()
```

ANEXO 5: CURSO PROPEDÉUTICO



Aspirantes a la V promoción de la Maestría en Matemática con orientaciones en Ingeniería matemática y estadística matemática - UNAH.

INSCRIPCIONES
CURSOS PROPEDÉUTICOS 2023
MODALIDAD PRESENCIAL
INVERSIÓN: L. 4,800.00 ^{€/u} | TOTAL: L. 14,400.00

Asignaturas:

- MMM-601 Álgebra Lineal
- MMM-602 Principios de Análisis Matemático
- MMM-603 Herramientas Computacionales

Dirigido a:

- Licenciados en Matemática
- Licenciaturas afines:
- Ingenierías, Física, Economía, Química, Biología, Computación, dependiendo del grado de formación en matemática.

Requisitos de inscripción para cursos propedéuticos:


- Solicitud de matrícula (descargar formulario en la página web: www.mm.unah.edu.hn) acompañada de una copia de la tarjeta de identidad
- Hoja de vida resumida (actualizada)
- Fotografía tamaño carnet
- Certificación de Estudios o Historial Académico reciente indicando el índice académico

Recepción de documentos:
A partir del lunes 14 de agosto al 11 de septiembre en la oficina administrativa de Maestría en Matemática-UNAH Edificio F1, Segundo nivel en un horario de 1:00 -7:00pm



Inicio de clases:
III PAC - 18 de septiembre 2023

Contactos:
Página Web de la Maestría en Matemática: www.mm.unah.edu.hn
Correo: maestria.matematica@unah.edu.hn
Coordinador General: Dr. Luis Berlioz

Es importante saber que para tomar los cursos propedéuticos no es obligatorio tener un título de licenciatura, pero debe de estar en los últimos periodos de su plan de estudios.



Maestría en Matemática



UNAH
UNIVERSIDAD NACIONAL AUTÓNOMA DE HONDURAS

ANEXO 6: CURSO DE PYTHON



RECEPCIÓN DE DOCUMENTOS:

del viernes 15 de octubre al 5 de noviembre del año 2021.

Perfil de postulantes al Curso:

Profesionales y estudiantes que se desempeñan en los distintos campos del conocimiento humano.

Datos de interés

Aportación económica	L. 2,000.00
Día	Sábado
Horario	De 8:00 a.M.- 12:00 m.D.
Duración	4 semanas (30 horas) 30 horas virtuales



CUPO LIMITADO

Para más información

Visita nuestra página web <https://mm.unah.edu.hn/>

Correo: maestria.matematica@unah.edu.hn



Maestría en
Matemática



UNAH
UNIVERSIDAD DE AMÉRICA

ANEXO 7: CURSO DE INTRODUCCIÓN A MACHINE LEARNING EN PYTHON



CURSO
MACHINE LEARNING EN PYTHON

Profesionales y estudiantes que se desempeñan en los distintos campos del conocimiento humano.

Datos de Interés

-  **Aportación Económica**
L. 3,000.00
-  **Día:** Sábado
Horario: 8:00 a.m.- 12:00 p.m.
-  **Duración:** 4 semanas (30 horas)
30 horas Virtuales

Inicio de clases
Sábado 09 de marzo del 2024

 **Recepción de documentos:**
Del lunes 15 de enero al 04 de marzo de 2024.

 **Perfil del Instructor**
MSc Henry David Ocampo Meraz
Docente de la Escuela de Matemática de la UNAH.

Máster en Ciencias de la Computación y Matemáticas Industriales, con especialidad en Análisis de Datos y Machine Learning, en el centro de Investigación en Matemáticas (CIMAT).

Contacto: maestria.matematica@unah.edu.hn

Para obtener más información visita nuestra web: www.mm.unah.edu.hn

CUPO LIMITADO

ANEXO 8: DIPLOMADO DE ESTADÍSTICA APLICADA

DIPLOMADO EN ESTADÍSTICA APLICADA

Modalidad Virtual 2023

Perfil de postulantes al Diplomado:
Profesionales y estudiantes que se desempeñan en los distintos campos del conocimiento humano.

INICIO DEL DIPLOMADO:
SABADO 9 DE SEPTIEMBRE DEL 2023.

Recepción de documentos:
del 10 de julio al 31 de agosto del 2023.

El diplomado tiene una duración de 198 horas en modalidad virtual de la siguiente manera:

Módulo	Actividad	Duración	Fecha	Horario
1	Estadística Descriptiva y probabilidad	36 horas	9, 16, 23, 30 sep	8:00 a.m. - 12:00 m.
2	Inferencia, distribuciones e intervalos de confianza	36 horas	14, 21, 28 oct - 4 de nov	8:00 a.m. - 12:00 m.
3	Regresión lineal simple y múltiple, análisis de varianzas	36 horas	11, 18, 25 nov - 2 dic	8:00 a.m. - 12:00 m.
4	Independencia de variables y muestreo	36 horas	27 ene - 3, 10, 17 feb	8:00 a.m. - 12:00 m.
5	Proyecto de Investigación	54 horas	24 de feb - 2, 9, 16, 23, 30 mar	8:00 a.m. - 12:00 m.

La aportación económica tiene un valor único de L.7,000.00 será cancelado en dos cuotas que a continuación se detallan:

1. Cuota/ L. 4,000.00: Se realizará previo al inicio del Diplomado.

2. Cuota/ L. 3,000.00: Al finalizar el tercer modulo del Diplomado.

CONTACTO
Página web: <https://mm.unah.edu.hr/>
Correo: maestria.matematica@unah.edu.hr