



UNIVERSIDAD NACIONAL AUTÓNOMA DE NICARAGUA, LEÓN

UNAN-LEÓN

ÁREA CONOCIMIENTO DE CIENCIAS Y TECNOLOGÍA

ÁREA ESPECÍFICA MATEMÁTICA Y ESTADÍSTICA

INGENIERÍA ESTADÍSTICA



MONOGRAFÍA PARA OPTAR AL TÍTULO DE ING. ESTADÍSTICA

Predicción del comportamiento de las remesas en Nicaragua

2000-2024

Autores:

Br. Yeser Javier Lagos Lopez

Br. Hanzel Yasmil Peralta Zapata

Tutora:

PhD. Laureana Adalila Molina Membreño

León, Nicaragua, 20/11/2024

2024: “45/19, La Patria, La Revolución”



UNIVERSIDAD NACIONAL AUTÓNOMA DE NICARAGUA, LEÓN

UNAN-LEÓN

ÁREA CONOCIMIENTO DE CIENCIAS Y TECNOLOGÍA

ÁREA ESPECÍFICA MATEMÁTICA Y ESTADÍSTICA

INGENIERÍA ESTADÍSTICA



MONOGRAFÍA PARA OPTAR AL TÍTULO DE ING. ESTADISTICA

Predicción del comportamiento de las remesas en Nicaragua

2000-2024

PRESENTADO POR:

Br. Yeser Javier Lagos Lopez_____

Br. Hanzel Yasnil Peralta Zapata_____

APROBADO POR:

PhD. Laureana Adalila Molina Membreño.

Tutora.

León, Nicaragua, 20/11/2024

2024: "45/19, La Patria, La Revolución



Resumen

La predicción del comportamiento de las remesas no solo es crucial para la estabilidad económica del país, sino que también tiene implicaciones directas en la vida de miles de familias que dependen de estas transferencias para su subsistencia diaria. Se realizó esta investigación haciendo uso de las herramientas estadísticas, aplicando técnicas de serie de tiempo para predecir la evolución de las remesas como ingreso en las familias nicaragüenses.

Este estudio tiene un enfoque cuantitativo correlacional, modelizando con el modelo SARIMA. Esta información fue procesada en el software estadístico lenguaje R. Por esta razón se plantea en esta investigación como objetivo general: Predecir el comportamiento de las remesas en Nicaragua de enero 2025-noviembre 2027 haciendo uso de las técnicas de series de tiempo, con el fin de mejorar la comprensión del comportamiento de estas transferencias a lo largo del tiempo.

El modelo SARIMA ofreció un mejor ajuste en comparación con ARIMA debido a su capacidad para manejar la estacionalidad en las remesas. La precisión del SARIMA se reflejó en intervalos de confianza más estrechos y una mejor capacidad para captar tendencias estacionales recurrentes. Para 2025, el pronóstico central proyecta que las remesas podrían llegar a aproximadamente 820 millones de dólares, con un intervalo de confianza que sugiere un rango entre 800 millones y 850 millones. Para 2026, se espera que las remesas alcancen entre 880 millones y 930 millones de dólares.

Para concluir, en diciembre de 2027, el pronóstico central indica que las remesas podrían superar los 950 millones de dólares, con un posible límite superior de cerca de 1,000 millones de dólares.



DEDICATORIA

A Dios, fuente inagotable de fortaleza y guía en cada paso de mi vida. Gracias por sostenerme en los momentos difíciles y por las bendiciones que me has dado. Que mi trabajo y mis logros sean siempre para tu gloria.

A mi madre, Elvia Lopez Lackwood quien vive en mi corazón y en mis recuerdos, porque su amor y sabiduría son el legado más grande que he recibido. Aunque no estés físicamente aquí, sé que me cuidas y me acompañas desde un lugar de paz. Te extraño y agradezco cada día todo lo que me diste.

A mi abuela, Guillermina Lackwood Maska quien me ha apoyado, se preocupa por mí y, en todo momento siempre creyó en mí, por lo que la considero un familiar muy valioso para mí.

A mi hermana, Vielka Jacqueline Müller Lopez y mi hermano, Yorjes Grikson Lagos Lopez, quienes han sido mis compañeros en esta travesía de la vida. Gracias por el apoyo incondicional. No hay mayor bendición que tenerlos a mi lado. Estaré eternamente agradecidos con ustedes por todo.

Yeser Javier Lagos Lopez



AGRADECIMIENTOS

A mi hermana, **Vielka Jacqueline Müller Lopez** quien jamás me dejó de apoyar en todo momento, siendo ella una segunda madre para mí. Infinitamente gracias

A mi hermano, **Yorjes Grikson Lagos Lopez** quien me apoyó incondicionalmente durante mis estudios universitarios. Gracias.

A mi tutora, **PhD. Laureana Adalila Molina Membreño**, quien ha sido una guía fundamental en mi desarrollo profesional. Gracias por su paciencia, su dedicación y por compartir su conocimiento. Su apoyo y confianza me han ayudado a crecer y a alcanzar nuevas metas. Su impacto en mi vida es una inspiración, y siempre valoraré todo lo que he aprendido de usted.

A mis amigos, gracias por ser esa familia que elegí, por estar a mi lado en cada paso de este camino y por brindarme su apoyo incondicional. Con ustedes, la vida es más alegre y los momentos difíciles son más llevaderos. Su amistad es un regalo invaluable en mi vida, y siempre estaré agradecido por contar con ustedes.

Yeser Javier Lagos Lopez



DEDICATORIA

A mí padre, Francisco José Peralta Poveda y a mi madre Milagro de los Ángeles Zapata Bárcenas con amor y cariño le dedico todo mi esfuerzo y dedicación en la realización de esta MONOGRAFÍA

Hanzel Yasmil Peralta Zapata



AGRADECIMIENTO

Con profunda estima y agradecimiento extendiendo mi más sincera gratitud a mi tutora, **PhD. Laureana Adalila Molina Membreño** su dedicación y su inestimable guía han sido pilar fundamental en la dirección y enriquecimiento de esta tesis.

Expreso mi agradecimiento a mi **compañero** de profesión **Yeser Javier Lagos Lopez**, quien ha sido de muchísima ayuda, no solo en la realización de la monografía sino, en todo el proceso de formación profesional.

Agradezco a todos los maestros que estuvieron en esta increíble etapa, gracias por sus enseñanzas durante estos años, fueron de gran ayuda, expreso mi gratitud y mi admiración hacia ellos... gracias.

Hanzel Yasmil Peralta Zapata



INDICE

I.	INTRODUCCIÓN	1
II.	ANTECEDENTES	3
III.	PLANTEAMIENTO DEL PROBLEMA	5
IV.	JUSTIFICACIÓN	6
V.	OBJETIVOS DE LA INVESTIGACIÓN	7
5.1.	Objetivo general	7
5.2.	Objetivos Específicos	7
VI.	MARCO TEÓRICO	8
6.1.	Concepto de Remesas.....	8
6.2.	Tipos de Remesas	8
6.3.	Beneficios y Limitaciones de las Remesas	8
6.3.1.	Ventajas	8
6.3.2.	Desventajas:	8
6.4.	Principales Usos de las Remesas	9
6.5.	Las series de tiempo	9
6.6.	Error Porcentual Absoluto Medio (MAPE).....	10
6.8.	Proceso Aleatorio y Estocásticos	11
6.9.	Concepto de Ruido Blanco.....	11
6.10.	Medias Móviles y Función de Correlación	11
6.11.	Función de Correlación Simple y Parcial	11
6.12.	Modelos de Series Temporales	11
6.12.1.	Modelos de Regresión Uniecuacionales	11
6.12.2.	Modelo ARIMA.....	11
6.12.3.	Proceso de Medias Móviles (MA)	12
6.13.	Proceso Autorregresivo Integrado de Media Móvil (ARIMA)	12
6.14.	Etapas para Elaborar un Modelo.....	13
6.15.	Modelos Predictivos.....	13
6.16.	Modelos de Regresión Lineal	13
6.17.	Modelos de Suavizamiento Exponencial	13



6.18.	Modelos de Machine Learning:	14
6.19.	Modelos Autorregresivos Integrados de Media Móvil (ARIMA).....	14
6.20.	Modelos SARIMA (Seasonal AutoRegressive Integrated Moving Average)	14
6.20.1.	Notación SARIMA	15
6.21.	Función de autocorrelación (ACF)	15
6.22.	Función de autocorrelación parcial (PACF).....	16
6.23.	Criterios de Información: AIC y BIC.....	17
6.23.1.	El AIC	17
6.23.2.	El BIC	17
VII.	DISEÑO METODOLÓGICO	18
7.1.	Tipo de estudio	18
7.2.	Periodo de estudio:	18
7.3.	Variables de estudio:	18
7.4.	Modelos matemáticos:	18
7.5.	Tipo de diseño	19
7.6.	Fuente de información.....	19
7.7.	Procedimiento.....	20
7.8.	Herramientas.....	20
VIII.	RESULTADOS	21
IX.	CONCLUSIÓN	38
X.	RECOMENDACIONES	39
XI.	CRONOGRAMA DE ESTUDIO	40
XII.	ANEXOS.....	41
XIII.	BIBLIOGRAFIA	46



I. INTRODUCCIÓN

Las remesas son un indicador clave de la economía nicaragüense para los ingresos de muchos hogares. Según el Banco Central de Nicaragua (2023), estima que las remesas representaron el 15% del producto interno bruto (PIB) de Nicaragua. Existe una amplia evidencia empírica que sugiere que las remesas tienen un impacto positivo en el nivel de vida de los hogares que las reciben. Sin embargo, la evidencia sobre el impacto de las remesas en el consumo es aún mixta. Algunos estudios encuentran que las remesas aumentan el consumo, mientras que otros no encuentran ningún efecto significativo.

Estas remesas son esenciales para muchas familias nicaragüenses, ya que les permiten cubrir necesidades básicas como; alimentación, vivienda, educación y salud. Además, las remesas también contribuyen a la inversión en pequeñas y medianas empresas, lo que impulsa el crecimiento económico del país.

Las estadísticas de las remesas son primordiales a nivel centroamericano para su desarrollo económico, regularmente los estudios de las remesas son abordados de las perspectiva económica, financiera y social. No obstante, existe poca documentación que aborde la metodología de sus predicciones que faciliten a los encargados de la contabilidad nacional evaluar de forma rápida y sencilla las variaciones del ingreso de las remesas a las familias nicaragüenses.

El análisis predictivo de las remesas no es una tarea sencilla. Implica la consideración de múltiples variables, incluyendo factores económicos globales, políticas migratorias, y condiciones macroeconómicas tanto en los países emisores como receptores. Estudios previos, como los realizados por García (2020) y Rodríguez (2019), han demostrado que la predicción precisa de las remesas puede proporcionar una ventaja significativa en la planificación económica y en la implementación de políticas públicas que busquen maximizar el impacto positivo de estas transferencias.



La predicción del comportamiento de las remesas no solo es crucial para la estabilidad económica del país, sino que también tiene implicaciones directas en la vida de miles de familias que dependen de estas transferencias para su subsistencia diaria. Se realizará esta investigación haciendo uso de las herramientas estadísticas, aplicando técnicas de serie de tiempo para predecir la evolución de las remesas como ingreso en las familias nicaragüenses. Este estudio tiene un enfoque cuantitativo correlacional, modelizando con el modelo SARIMA. Esta información será procesada el software estadístico lenguaje R. Por esta razón es que se plantea en esta investigación como objetivo general: Predecir el comportamiento de las remesas en Nicaragua de enero 2025-noviembre 2027 haciendo uso de las técnicas de series de tiempo, con el fin de mejorar la comprensión del comportamiento de estas transferencias a lo largo del tiempo.

Esta tesis representa un desafío significativo para los profesionales en estadística, ya que estudios de esta naturaleza son fundamentales para los estudiantes de Ingeniería Estadística, quienes enfrentarán retos similares en su futura profesión. Los resultados de este estudio pueden servir como base para la toma de decisiones, el diseño de políticas y la implementación de estrategias económicas orientadas a mejorar el bienestar de la población.



II. ANTECEDENTES

En la Universidad de Costa Rica (UCR) se desarrolló una tesis, donde se investigó la dinámica de las remesas hacia Costa Rica, un país que recibe un volumen menor en comparación con otras naciones centroamericanas. El estudio utilizó técnicas de descomposición de series temporales y modelos de suavización exponencial, lo que permitió identificar una tendencia creciente en la recepción de remesas, impulsada por la mejora en las condiciones laborales de los migrantes costarricenses en los Estados Unidos y España (**González, 2021**).

El autor **García (2020)** ha explorado acerca de cómo las remesas han impulsado el desarrollo local en comunidades que de otra manera estarían condenadas a la marginación. Su estudio muestra que, más allá de satisfacer necesidades inmediatas, las remesas han financiado proyectos comunitarios importantes, ayudando a construir una infraestructura social más sólida. Sin embargo, también advierte sobre los peligros de depender excesivamente de estas transferencias, subrayando la vulnerabilidad que esto puede generar ante cualquier interrupción en el flujo de remesas, lo que pone de manifiesto la importancia de diversificar las fuentes de ingresos en las familias receptoras.

En una tesis realizada en la Universidad de San Carlos de Guatemala (USAC), se investigó el comportamiento de las remesas hacia Guatemala, un país con una alta dependencia de este ingreso. El análisis se enfocó en las variables macroeconómicas como el tipo de cambio y el Producto Interno Bruto (PIB) de los Estados Unidos, ya que la mayoría de las remesas provienen de ese país. Los resultados demostraron que los modelos ARIMA fueron adecuados para predecir las remesas en el corto plazo, aunque con limitaciones en periodos de alta volatilidad económica (**Hernández, 2020**).



En la Universidad de El Salvador, una tesis exploró, las tendencias de las remesas en ese país, identificando su rol crucial en la economía doméstica. Se aplicaron diferentes modelos de predicción, como ARIMA y VAR, y se concluyó que las remesas tienen un comportamiento estacional, influenciado por la economía estadounidense y las festividades religiosas. Las proyecciones indicaron que, en periodos de recesión en Estados Unidos, las remesas disminuyen, lo que afecta el consumo interno y las inversiones locales (**Martínez, 2019**).

El autor **Rodríguez (2019)** destaca que se ha enfocado en el impacto de las remesas en el acceso a servicios de salud. Su investigación indica que las familias que reciben remesas tienen mayores probabilidades de acceder a servicios médicos privados, lo que contribuye a reducir las brechas en salud dentro del país. No obstante, también subraya que estas mejoras no son necesariamente sostenibles si las remesas disminuyen, lo que plantea importantes desafíos para las políticas públicas en materia de salud.

En México se presenta una tesis relacionada con el análisis de series temporales y la predicción económica de remesas, un área que se ha convertido en un elemento crucial en la evaluación de las economías regionales. Su autor, **Juan Carlos García Díaz (2011)** en su obra Series temporales, análisis y predicción: ejercicios prácticos brinda una perspectiva sólida sobre la aplicación de métodos de predicción económica, utilizando series temporales como herramienta principal. Estos métodos han sido ampliamente utilizados en México para evaluar las tendencias de las remesas, un tema fundamental para la estabilidad económica.



III. PLANTEAMIENTO DEL PROBLEMA

Nicaragua es uno de los países con una alta dependencia de las remesas, las cuales constituyen una fuente crucial de ingresos para los hogares nicaragüenses. En este estudio, se busca analizar cómo se ha comportado la economía nicaragüense y los cambios ocurridos durante el período 2000-2024, considerando las remesas recibidas como un factor determinante. En este contexto, es fundamental examinar la tendencia de las remesas recibidas en Nicaragua a lo largo de este período, con el objetivo de comprender su comportamiento y su impacto en la economía del país.

Tomando en cuenta lo anteriormente mencionado, nos genera la siguiente pregunta:

¿Cómo ha evolucionado la tendencia de las remesas recibidas en Nicaragua durante el período 2000-2024?

IV. JUSTIFICACIÓN

Por los estudios revisados en antecedentes, se observó que a lo largo del tiempo, las remesas han sido un sustento muy importante en los hogares nicaragüenses, por ello, se decidió llevar a cabo la presente investigación con el objetivo de poder visualizar mediante análisis estadísticos, el comportamiento de las remesas que se reciben en el país anualmente así como predecir el futuro de las remesas que se recibirán durante los próximos años, las cuales serán de mucha utilidad para los hogares nicaragüenses. Al mismo tiempo, estas entregas monetarias tienen un impacto directo en el bienestar de las familias receptoras, facilitando sus condiciones de vida y ampliando sus accesibilidades.

Las remesas desempeñan un papel primordial en la economía nicaragüense, actuando como un amortiguador ante las dificultades que se vive en la mayoría de los hogares nicaragüenses y, de esta manera, contribuyendo a la estabilidad macroeconómica.

Este estudio monográfico será de utilidad, para saber, si habrá una mejora significativa en Nicaragua durante los próximos 3 años y por supuesto, esto implica que podemos determinar mediante el uso de las técnicas de series temporales, si habrá un aumento en las remesas de nuestro país, otorgando una mejor calidad de vida para los beneficiados.

Además, esta investigación también será de utilidad, como referencia para las futuras generaciones de estudiantes y/o público que se encuentren interesados en un tema similar que ellos(as) deseen abordar.



V. OBJETIVOS DE LA INVESTIGACIÓN

5.1. Objetivo general

- Predecir el comportamiento de las remesas en Nicaragua de enero 2000-mayo 2024 haciendo uso de las técnicas de series temporales.

5.2. Objetivos Específicos

- Describir el comportamiento del ingreso de la remesa en tasas de variaciones de enero-2000 a mayo-2024.
- Comparar modelos de series temporales como: ARIMA y SARIMA para analizar las diferencias en los resultados pronosticados.
- Estimar el modelo de predicción de las remesas nicaragüenses aplicando modelo SARIMA para el periodo junio-2024 a noviembre-2027.

VI. MARCO TEÓRICO

6.1. Concepto de Remesas

Las remesas son envíos de dinero hechos por emigrantes a sus países natales. Según Ratha (2013), estas remesas generan un impacto significativo en la economía de los países que las reciben, lo cual contribuye a mejorar el bienestar de los hogares y fomentar el crecimiento económico. Según el Banco Central de Nicaragua (2020), las remesas en Nicaragua no solo ayudan a reducir la pobreza, sino que también impulsan la inversión en áreas como salud, educación y pequeñas empresas.

6.2. Tipos de Remesas

1. **Remesas familiares:** Envío de dinero realizado por inmigrantes para apoyar a sus familiares en su país de origen.
2. **Remesas sociales:** Recursos enviados para iniciativas de la comunidad o proyectos con un enfoque social.
3. **Remesas de inversión:** Dinero enviado con la intención de ser invertido en negocios o propiedades en el lugar de origen.

6.3. Beneficios y Limitaciones de las Remesas

6.3.1. Ventajas

1. Reducir la pobreza (Adams & Cuecuecha, 2013).
2. Promueve la dinamización de la economía local (Chami, Fullenkamp, & Jahjah, 2005).
3. Se busca mejorar la salud y educación (Ratha, 2013).

6.3.2. Desventajas:

1. La dependencia económica es un tema abordado por Chami, Fullenkamp y Jahjah en su investigación de 2005.
2. Existe la posibilidad de que haya variaciones en la economía (World Bank, 2011).



3. Es posible que se incremente la brecha de desigualdad. Componentes Principales de las Series de Tiempo. (Adams & Cuecuecha, 2013)

6.4. Principales Usos de las Remesas

1. Consumo: Mejora el nivel de vida y cubre necesidades básicas (Ratha, 2013).
2. Inversión: Financia pequeñas empresas y proyectos productivos (Adams & Cuecuecha, 2013).
3. Ahorro: Proporciona seguridad financiera y recursos para el futuro (Chami, Fullenkamp, & Jahjah, 2005).

6.5. Las series de tiempo

Se componen de varios componentes claves que permiten analizar y predecir los datos: Las series de tiempo se componen de varios componentes claves que permiten analizar y predecir los datos:

1. **Tendencia** Time Series Analysis (Hamilton, 1994) establece que el comportamiento a largo plazo puede ser de crecimiento o decrecimiento general.
2. **Estacionalidad**: Fluctuaciones periódicas y previsibles en intervalos regulares (Hyndman & Athanasopoulos, 2018).
3. **Ciclo**: Las fluctuaciones económicas a largo plazo pueden no ser necesariamente regulares (Box, Jenkins y Reinsel, 2015).
4. **Ruido aleatorio**: Cambios inesperados y descontrolados (Hamilton, 1994).

Relaciones y Rangos de Confianza

La correlación cuantifica la conexión existente entre dos variables en una secuencia de tiempo. Según Greene (2018), las bandas de confianza ofrecen un intervalo en el que es probable encontrar los valores verdaderos con cierto nivel de certeza.

Para calcular la correlación se utiliza la siguiente expresión:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

donde X y Y son las dos variables, y $\bar{X}$ y $\bar{Y}$ son sus medias (Wooldridge, 2016).

6.6. Error Porcentual Absoluto Medio (MAPE)

El MAPE mide la precisión de un modelo de predicción:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100$$

donde Y_t es el valor real y $\hat{Y}_t$ es el valor predicho (Hyndman & Athanasopoulos, 2018).

6.7. R-Cuadrado y R-Cuadrado Ajustado

El R-cuadrado mide la proporción de la variabilidad total explicada por el modelo:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

El R-cuadrado ajustado ajusta el R^2 según el número de predictores en el modelo:

$$R_{adj}^2 = 1 - \left(\frac{1 - R^2}{n - k - 1} \right) (n - 1)$$

donde k es el número de predictores y n es el número de observaciones (Greene, 2018).



6.8. Proceso Aleatorio y Estocásticos

Un proceso aleatorio es una colección de variables aleatorias indexadas en el tiempo. Los procesos estocásticos son aquellos en los que la evolución temporal está determinada por la probabilidad (Hamilton, 1994).

6.9. Concepto de Ruido Blanco

Time Series Analysis (Hamilton, 1994), el ruido blanco es un proceso estocástico con media cero, varianza constante y ausencia de autocorrelación.

6.10. Medias Móviles y Función de Correlación

Medias Móviles (MA): Es una técnica que promedia un número consolidado de puntos de datos sucesivos (Box, Jenkins, & Reinsel, 2015).

6.11. Función de Correlación Simple y Parcial

La función de correlación simple mide la relación lineal entre valores de la serie a diferentes aplazamientos. La función de correlación parcial mide la relación lineal excluyendo la influencia de otros retardos según (Hamilton, 1994).

6.12. Modelos de Series Temporales

6.12.1. Modelos de Regresión Uniecuacionales

Modelos que explican una variable dependiente usando una o más variables independientes, sin considerar efectos de autocorrelación (Wooldridge, 2016).

6.12.2. Modelo ARIMA

El modelo ARIMA (Autoregressive Integrated Moving Average) es uno de los más utilizados para el análisis y la predicción de series temporales. Combina tres componentes:

1. **Autorregresivo (AR):** Los valores pasados de la serie se usan para predecir el valor actual.
2. **Integrado (I):** Diferenciación de la serie temporal para hacerla estacionaria.
3. **Media Móvil (MA):** Modela la relación entre el valor de la serie y los errores pasados.

La forma general del modelo ARIMA es:

$$\text{ARIMA}(p, d, q): Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

donde:

- p : es el orden del modelo autorregresivo.
- d : es el grado de diferenciación.
- q : es el orden del modelo de media móvil.
- Y_t : es el valor actual de la serie.
- ε_t : es el término de error aleatorio (Hamilton, 1994).

6.12.3. Proceso de Medias Móviles (MA)

Un proceso MA se define como:

$$Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

donde ε_t es el término de error aleatorio (Box, Jenkins, & Reinsel, 2015).

6.12.4. Proceso Autorregresivo de Media Móvil (ARMA)

Combina componentes AR y MA:

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

6.13. Proceso Autorregresivo Integrado de Media Móvil (ARIMA)

El modelo ARIMA incluye un componente de diferenciación:

$$\text{ARIMA}(p,d,q): Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

6.14. Etapas para Elaborar un Modelo

1. Identificación: Determinar el tipo de modelo (AR, MA, ARMA, ARIMA) (Box, Jenkins, & Reinsel, 2015).
2. Estimación: Estimar los parámetros del modelo (Hamilton, 1994).
3. Diagnóstico: Verificar la adecuación del modelo (Hyndman & Athanasopoulos, 2018).
4. Pronóstico: Utilizar el modelo para hacer predicciones (Hamilton, 1994).

6.15. Modelos Predictivos

Los modelos predictivos son herramientas fundamentales en la econometría y análisis de series temporales, ya que permiten hacer pronósticos basados en datos históricos.

Entre los principales modelos predictivos utilizados en la econometría se encuentran:

6.16. Modelos de Regresión Lineal

La regresión lineal simple modela la relación entre una variable dependiente y una independiente. La forma general es:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

donde Y es la variable dependiente, X la independiente, β_0 y β_1 son los coeficientes para estimar, y ε es el término de error (Wooldridge, 2016).

6.17. Modelos de Suavizamiento Exponencial

Utilizados para datos con tendencia y estacionalidad. El método de Holt-Winters es un ejemplo:

Nivel:
$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1})$$

Tendencia:
$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$



Estacionalidad: $S_t = \gamma(Y_t - (L_{t-1} + T_{t-1})) + (1 - \gamma)S_{t-s}$

Pronóstico: $\hat{Y}_{t+h}|t = L_t + hT_t + S_{t+h-s}$

donde α , β , y γ son parámetros de suavizamiento, y s es el periodo estacional (Hyndman & Athanasopoulos, 2018).

6.18. Modelos de Machine Learning:

Técnicas como los bosques aleatorios, redes neuronales y métodos de soporte vectorial están siendo cada vez más utilizadas para la predicción de series temporales debido a su capacidad para manejar relaciones complejas y no lineales (James et al., 2013).

6.19. Modelos Autorregresivos Integrados de Media Móvil (ARIMA)

El modelo ARIMA, ampliamente utilizado en análisis de series temporales, se expresa como:

$$ARIMA(p, d, q): Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q}$$

p : es el orden del modelo autorregresivo.

d : es el grado de diferenciación.

q : es el orden del modelo de media móvil.

Y_t : es el valor actual de la serie.

ϵ_t : es el término de error aleatorio (Hamilton, 1994).

6.20. Modelos SARIMA (Seasonal AutoRegressive Integrated Moving Average)

El modelo SARIMA que refleja la característica de variación estacional en series de tiempo. Generalmente, la serie de tiempo original $\{Y_t\}$ utiliza un operador de retardo B para procesar SARIMA $(p, d, q) \times (P, D, Q)_s$.

Un ARIMA estacional el modelo puede escribirse como:

$$\phi(B)\phi_p(B^S)(1-B)(1-B^S)^D Y_t = \theta_q(B)\theta_q(B^S)\epsilon_t.$$

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta_p(B^S) = 1 - \theta_S B^S - \theta_{S^2} B^{S^2} - \dots - \theta_{pS} B^{pS}$$

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_q B^q$$

$$\theta_q(B^S) = 1 - \theta_S B^S - \theta_{S^2} B^{S^2} - \dots - \theta_{qS} B^{qS}.$$

Donde $\phi(B)$ y $\theta(B)$ son polinomios de orden p y q , $\Phi(B^S)$ y $\Theta(B^S)$ son polinomios en B^S de grados P y Q , respectivamente p es el orden de autorregresión no estacional; d es el número de diferencias regulares; q es el orden de la media móvil no estacional; P es el orden de autorregresión estacional; D es el número de diferencias estacionales; Q es el orden de la media móvil estacional; y S es la duración de la temporada (Chinlli, s. f.).

6.20.1. Notación SARIMA

SARIMA(p,d,q)(P,D,Q)_s

1. p, d, q : Órdenes de los componentes AR, I y MA, respectivamente, para la parte no estacional.
2. P, D, Q : Órdenes de los componentes AR, I y MA, respectivamente, para la parte estacional.
3. s : Período de estacionalidad.

6.21. Función de autocorrelación (ACF)

La función de autocorrelación (ACF, por sus siglas en inglés) es una herramienta fundamental en el análisis de series temporales, ya que permite medir la correlación entre los valores de una serie temporal con sus versiones retardadas. En términos simples, la ACF muestra cómo un valor en un momento específico está correlacionado con los valores anteriores en la misma serie.

Esta herramienta es esencial para detectar patrones de dependencia temporal y determinar la estacionariedad de los datos (Box et al., 2016).

Matemáticamente, la autocorrelación en el lag k está dada por:

$$\gamma(k) = \frac{\sum_{t=k+1}^n (X_t - \bar{x})(X_{t-k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}$$

donde X_t representa el valor en el tiempo t , $\bar{x}$ es el promedio de la serie y k es el retraso o "lag". La ACF es fundamental en el análisis preliminar de datos temporales para identificar la presencia de correlaciones entre los valores observados en diferentes puntos en el tiempo.

6.22. Función de autocorrelación parcial (PACF)

Por otro lado, la función de autocorrelación parcial (PACF) ofrece una medida de la correlación entre los valores de la serie temporal, pero eliminando la influencia de los lags intermedios. Es decir, a diferencia de la ACF, que considera todas las correlaciones hasta un determinado lag, la PACF se enfoca solo en la relación directa entre un valor y su retraso, ignorando los valores intermedios. La PACF es especialmente útil para identificar el número de rezagos que deben incluirse en modelos autorregresivos (Chatfield, 2019).

Su fórmula general se expresa como:

$$\phi(k) = ACF(k) - \sum_{i=1}^{k-1} \phi(i) \cdot ACF(k-i)$$

Donde $\phi(k)$ representa el coeficiente de autocorrelación parcial en el lag k . Interpretar la PACF es crucial para la selección de modelos autorregresivos, como los modelos AR(p).

6.23. Criterios de Información: AIC y BIC

Los criterios de información de Akaike (AIC) y Bayesiano (BIC) son métodos estadísticos que permiten seleccionar el mejor modelo dentro de un conjunto de modelos candidatos, ajustando la calidad del ajuste y penalizando la complejidad del modelo. Ambos criterios buscan equilibrar el ajuste y la simplicidad del modelo, para evitar el sobreajuste, aunque el BIC es más riguroso en la penalización de la complejidad (Burnham & Anderson, 2004).

6.23.1. El AIC

se define como:

$$AIC = 2k - 2\ln(L)$$

Donde k es el número de parámetros del modelo y L es la función de verosimilitud máxima del modelo. Este criterio es útil para comparar modelos y elegir aquel que mejor balancee el ajuste y la parsimonia (Akaike, 1974).

6.23.2. El BIC

También conocido como Criterio de Información de Schwarz, es similar, pero penaliza más fuertemente los modelos complejos. Su fórmula es:

$$BIC = \ln(n)k - 2\ln$$

Donde n es el tamaño de la muestra. En comparación con el AIC, el BIC tiende a seleccionar modelos más simples cuando se dispone de grandes volúmenes de datos, siendo más conservador (Schwarz, 1978).

VII. DISEÑO METODOLÓGICO

7.1. Tipo de estudio

El estudio se desarrolló con un enfoque cuantitativo, correlacional, tomando en cuenta que durante el análisis se hizo uso de datos cuantificables y es de corte longitudinal porque las observaciones inician en enero 2000-2024. Es prospectivo porque se desea predecir el futuro de las remesas recibidas en Nicaragua del 2025 a 2027.

7.2. Periodo de estudio:

Enero-2000 hasta Mayo-2024, para un total de 293 meses.

7.3. Variables de estudio:

remesa en mdd. (años, meses)

7.4. Modelos matemáticos:

Modelo ARIMA (2, d, 2)

se representa matemáticamente como:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \epsilon_t$$

donde:

Y_t representa el valor de la serie en el tiempo t ,

ϕ_1 y ϕ_2 son los coeficientes de los términos autorregresivos (AR),

θ_1 y θ_2 son los coeficientes de los términos de media móvil (MA),

ϵ_t es el error en el tiempo t .

Sustituyendo los valores estimados:

$$Y_t = -1.353Y_{t-1} - 0.5868Y_{t-2} - 0.1022\epsilon_{t-1} - 0.7999\epsilon_{t-2} + \epsilon_t$$

Modelo Matemático SARIMA (2, d, 2) (1, 1, 1) [12]

Un modelo SARIMA (2, d, 2) (1, 1, 1) [12] se representa matemáticamente como:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \Phi_1 Y_{t-12} + \Theta_1 \epsilon_{t-12} + \epsilon_t$$

donde:

Y_t : valor de la serie en el tiempo t ,

ϕ_1, ϕ_2 : coeficientes autorregresivos no estacionales,

θ_1, θ_2 : coeficientes de media móvil no estacionales

Φ_1 : coeficiente autorregresivo estacional,

Θ_1 : coeficiente de media móvil estacional,

ϵ_t : error en el tiempo t .

Sustituyendo los valores estimados:

$$Y_t = 0.3912Y_{t-1} + 0.2667Y_{t-2} - 1.63\epsilon_{t-1} + 0.6342\epsilon_{t-2} - 0.1587Y_{t-12} - 0.3906\epsilon_{t-12} + \epsilon_t$$

7.5. Tipo de diseño

No experimental debido a que no estuvimos presente durante la recolección de información.

7.6. Fuente de información

Es secundaria, se utilizó los datos de remesas en Excel del Banco Central de Nicaragua (BCN) del período de análisis, obtenidos desde su página Web.

7.7. Procedimiento

Se realizó la conversión de los datos de remesas a una serie temporal con el objetivo de llevar a cabo un análisis visual e interpretativo a lo largo del tiempo. Una vez convertidos, se interpretaron los resultados de la serie descompuesta, lo que permitió comprender mejor los componentes periódicos y estacionales de las remesas.

Posteriormente, se aplicó la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF) para analizar la dependencia temporal de la serie.

Esto ayudó a determinar que la serie es no estacionaria. Se realizó una transformación para alcanzar la estacionariedad para facilitar el presente estudio de interés.


Finalmente, se procedió con el análisis de los modelos propuestos en este estudio y se seleccionó el modelo basándose en los indicadores. Criterio de información de Akaike (AIC) y el Criterio de información bayesiano (BIC), lo que permitió realizar un pronóstico preciso de las remesas en Nicaragua.

7.8. Herramientas

Se hizo uso del software estadístico R, donde se importó la base de datos desde Excel al programa R para la conversión de los datos de remesas a una serie temporal y generar los resultados de los modelos, cuyo propósito es, determinar el modelo adecuado para la predicción de las remesas en Nicaragua. Para la redacción del informe se utilizó los programas de Microsoft office Word y Power point para la presentación de los resultados. Finalmente, el programa Zotero y su complemento web para realizar las citas y referencias bibliográficas.

VIII. RESULTADOS

Figura 1. Remesas recibidas en millones de dólares.




En la figura 1, desde el año 2000 hasta 2024, se observa un crecimiento sostenido en el flujo de remesas, mostrando una tendencia ascendente.

Entre 2000 y aproximadamente 2018, el crecimiento es moderado y lineal, con fluctuaciones menores. Sin embargo, a partir de 2018, se evidencia una aceleración significativa en el crecimiento de las remesas, pasando de valores cercanos a los 200 millones de dólares a más de 400 millones en 2024. Este cambio puede estar asociado con factores económicos externos o variaciones en el comportamiento de la diáspora.

En los últimos años, especialmente desde 2020, la tasa de crecimiento parece haberse incrementado notablemente, lo que puede estar vinculado a factores coyunturales como la crisis económica global post-pandemia, que podría haber motivado un aumento en el envío de remesas hacia Nicaragua.

Figura 2. La función de autocorrelación (ACF) no estacionaria




En la fig.2. La ACF muestra valores altos de autocorrelación que decaen lentamente con el aumento del "lag" (el retraso entre observaciones), lo cual es característico de una serie no estacionaria. Esto significa que los datos de remesas presentan una tendencia o patrones que no se mantienen constantes a lo largo del tiempo.

En la serie, los primeros valores de la autocorrelación están muy cerca de 1, lo que indica que los valores de remesas actuales están altamente correlacionados con los valores de periodos recientes. En palabras simples, esto nos dice que las remesas que entraron en meses pasados influyen de manera fuerte en los montos de los meses siguientes.


A medida que los lags, la autocorrelación va disminuyendo de manera gradual. Sin embargo, nunca cae bruscamente ni se aproxima a cero rápidamente, lo cual es otra señal de que la serie sigue una tendencia y no es estacionaria

Figura 3. la función de autocorrelación parcial (PACF)




El primer valor de la PACF es alto y está cerca de 1, lo cual indica que las remesas en el periodo actual están fuertemente relacionadas solo con el periodo inmediatamente anterior (lag 1). Esto es característico en series no estacionarias, donde el valor actual depende en gran medida del valor pasado. Después del primer lag, la PACF disminuye bruscamente y los valores para los siguientes lags caen cerca de cero (aunque hay pequeñas fluctuaciones en algunos lags). Esta rápida disminución sugiere que una vez que tomamos en cuenta la relación con el primer lag, no quedan relaciones significativas entre los valores actuales y los de lags más lejanos. En términos simples, esto sugiere que la influencia de los valores pasados en el valor actual de la serie disminuye rápidamente después del primer periodo. Esta estructura de la PACF sugiere que, para hacer que la serie sea estacionaria o para modelarla, una diferenciación de primer orden podría ser suficiente, ya que la dependencia directa con valores pasados desaparece rápidamente. Esto significa que la serie puede necesitar una transformación para eliminar la tendencia y hacer que los datos sean más consistentes a lo largo del tiempo.

Figura 4. Serie diferenciada de remesas




En la fig.4 se muestra que, al aplicar la diferenciación, se ha logrado eliminar la tendencia creciente en la serie original, haciendo que los datos oscilen alrededor de un valor medio cercano a cero. Esto es un buen indicio de que la serie podría ser ahora estacionaria, lo cual facilita el análisis y la modelación de datos en series temporales. Observamos que la serie diferenciada presenta fluctuaciones más fuertes en los últimos años, especialmente después de 2015. Esto indica que la variabilidad en las remesas ha aumentado con el tiempo, lo cual podría estar asociado a factores económicos o sociales específicos de ese periodo. La serie diferenciada parece ahora más estable y adecuada para el análisis, ya que la eliminación de la tendencia ayuda a cumplir el requisito de estacionariedad.

Figura 5. Función de autocorrelación (ACF) de la serie estacionaria




En la figura 5, se observa que algunos lags (por ejemplo, 1, 4, 8, y 12) tienen correlaciones significativas, ya que sus barras sobrepasan las líneas de puntos azules que representan los intervalos de confianza al 95%. Esto indica que hay una relación estadísticamente significativa entre los valores de la serie en esos retardos específicos. La presencia de correlaciones altas en intervalos regulares, como en los lags 4, 8, y 12, puede sugerir estacionalidad. Esto podría interpretarse como patrones que se repiten trimestralmente, reflejando un posible comportamiento cíclico en las remesas, asociado con ciertas épocas del año en las que se envía más dinero. Dado que la ACF disminuye relativamente rápido y no muestra un decaimiento lento, sugiere que la serie es estacionaria. En términos simples, una serie estacionaria es aquella donde las propiedades estadísticas, como la media y la varianza, se mantienen constantes a lo largo del tiempo. Esto se logró mediante una transformación de los datos originales aplicando diferenciación en la serie.

Figura 6. Función de autocorrelación parcial (PACF) de la serie estacionaria.



En la figura 6, observamos que algunos lags, especialmente el lag 1, tienen una correlación significativa por debajo de las líneas punteadas azules. Esto indica que, después de ajustar por lags intermedios, hay una fuerte relación entre el valor actual de las remesas y el valor del mes anterior. La PACF muestra que, después de los primeros lags especialmente después del lag 1, la correlación disminuye considerablemente y las barras caen dentro de los límites de confianza. Este gráfico PACF respalda la idea de que las remesas presentan una dependencia temporal corta.

Figura 7. Descomposición de la serie temporal



La primera sección del gráfico muestra los valores originales de la serie temporal de remesas recibidas. Tal como se observó anteriormente, se puede ver una tendencia de crecimiento sostenido y acelerado en los últimos años, lo que indica un aumento progresivo en el flujo de remesas hacia el país.

La segunda sección muestra la tendencia a largo plazo en la serie. Desde el año 2000 hasta aproximadamente el 2018, la tendencia es ligeramente ascendente. Sin embargo, a partir de 2018, la pendiente se incrementa notablemente, lo que sugiere una aceleración en el crecimiento de las remesas. Este cambio en la pendiente refuerza la idea de un aumento en la dependencia económica de las remesas.

La tercera sección muestra el componente estacional de la serie, indicando patrones repetitivos en el envío de remesas a lo largo de los años. Estos patrones de variación estacional suelen estar asociados a factores cíclicos o festividades que afectan el flujo mensual de remesas, mostrando picos y valles que sugieren periodos de mayor y menor actividad en el envío de dinero.

La última sección presenta el residuo, que representa las variaciones aleatorias o irregularidades de la serie que no son explicadas por la tendencia o la estacionalidad. Se observa que las fluctuaciones en el residuo aumentan ligeramente a partir de 2019, lo que podría deberse a factores externos o choques temporales en la economía global o local.

Tabla 1. Modelo ARIMA

p <- 2 # Número de retardos en la parte autorregresiva (AR)

d <- ndiffs_value # Diferenciación necesaria para lograr estacionariedad

q <- 2 # Número de términos en la parte de media móvil (MA)

Coefficient	ar1	ar2	ma1	ma2
Estimado	-1.353	-0.5868	-0.1022	-0.7999
Error Estándar	0.0529	0.0488	0.0367	0.0353

Estadístico	Sigma^2	Log Likelihood	AIC	ME	
Valor	102	-1087.85	2185.69	0.65007	
RMSE	MAE	MPE	MAPE	MASE	ACF1
10.06545	6.281392	-0.2746593	6.049983	0.7821606	0.05375762



Coeficientes del Modelo

AR Coefficients (ar1, ar2):

Estimado:

ar1 = -1.353: Este coeficiente indica una relación negativa entre el valor actual y el valor dos periodos atrás. Un valor absoluto mayor a 1 sugiere un comportamiento explosivo en la serie.

ar2 = -0.5868: Este coeficiente también es negativo, indicando que el valor actual se relaciona negativamente con el valor un periodo atrás, pero de manera más moderada.

MA Coefficients (ma1, ma2):

Estimado:

ma1 = -0.1022: Este coeficiente indica que hay un efecto negativo pequeño del error del periodo anterior en el valor actual.

ma2 = -0.7999: Este coeficiente muestra un efecto negativo significativo del error dos periodos atrás, lo que sugiere que este error tiene un impacto notable en el comportamiento actual de la serie.

Estadísticas del Modelo

Sigma² (Varianza del error): 102. Este valor refleja la varianza de los errores de predicción del modelo. Un valor alto puede indicar un modelo que no captura adecuadamente la variabilidad de la serie.

Log Likelihood: -1087.85. Este valor indica la log-verosimilitud del modelo. Valores más altos (menos negativos) indican un mejor ajuste del modelo a los datos.



AIC (Criterio de Información de Akaike): 2185.69. El AIC penaliza la complejidad del modelo. Un valor más bajo sugiere un modelo mejor ajustado. Este valor se debe comparar con otros modelos para evaluar la calidad relativa.

ME (Error Medio): 0.65007. Este valor representa el promedio de los errores de predicción. Un valor cercano a cero es deseable, indicando un modelo que no sistemáticamente sobreestima o subestima.

Métricas de Error

RMSE (Raíz del Error Cuadrático Medio): 10.06545. Esta métrica indica la magnitud promedio de los errores de predicción en las mismas unidades que los datos originales. Valores más bajos indican mejor ajuste.

MAE (Error Absoluto Medio): 6.281392. Este valor mide la media de los errores absolutos, proporcionando otra perspectiva sobre la precisión del modelo. Un valor bajo indica que las predicciones son en promedio cercanas a los valores observados.

MPE (Error Porcentual Medio): -0.2746593. Este valor indica el sesgo porcentual de las predicciones, siendo negativo sugiere que el modelo tiende a subestimar.

MAPE (Error Porcentual Absoluto Medio): 6.049983. Este valor mide el error porcentual medio con relación a los valores observados, expresado como un porcentaje. Es útil para entender la precisión relativa del modelo.

MASE (Error Absoluto Medio Escalado): 0.7821606. Este valor permite comparar el rendimiento del modelo con un modelo de referencia. Un valor menor que 1 sugiere que el modelo es mejor que un modelo naïve.

ACF1 (Función de Autocorrelación en el Lag 1): 0.05375762. Este valor cercano a cero indica que no hay correlación significativa entre los errores en el primer periodo, sugiriendo que el modelo ha capturado adecuadamente la estructura temporal de la serie. En general, el modelo ARIMA (2, d, 2) muestra una buena capacidad de ajuste a la serie

temporal analizada. Los coeficientes de autorregresión y media móvil indican relaciones significativas con los periodos anteriores, y las métricas de error sugieren que el modelo tiene un rendimiento razonable en términos de precisión predictiva.

Tabla 2. Modelo SARIMA

P <- 1 # Número de retardos en la parte autorregresiva estacional (AR)

D <- 1 # Diferenciación estacional

Q <- 1 # Número de términos en la parte de media móvil estacional (MA)

s <- 12 # Frecuencia estacional (mensual)

Coefficient	ar1	ar2	ma1	ma2	sar1	sma1
Estimado	0.3912	0.2667	-1.63	0.6342	-0.1587	-0.3906
Error estándar	0.3462	0.0835	0.3513	0.3441	0.1685	0.1722

Estadístico	Sigma^2	Log Likelihood	AIC	ME	RMSE
Valor	49.32	-946.87	1907.74	0.3642384	6.852828

Estadístico	MAE	MPE	MAPE	MASE	ACF1
Valor	3.958629	0.1706179	3.700246	0.4929295	-0.00314043

Coeficientes del Modelo

AR Coefficients (ar1, ar2):

ar1 = 0.3912: Este coeficiente indica una relación positiva entre el valor actual y el valor de la serie estacional del año anterior. Un valor moderado indica una dependencia moderada.

ar2 = 0.2667: Este coeficiente también refleja una dependencia positiva, aunque más débil, con el valor de hace dos periodos (24 meses atrás).

MA Coefficients (ma1, ma2):

ma1 = -1.63: Este coeficiente negativo indica un impacto negativo significativo del error del periodo anterior (mes anterior) en la predicción. Un valor absoluto mayor que 1 sugiere un comportamiento no lineal o una fuerte influencia de los errores pasados.

ma2 = 0.6342: Este coeficiente muestra un impacto positivo del error dos periodos atrás, pero con un efecto más moderado.

SAR Coefficients (sar1):

sar1 = -0.1587: Este coeficiente refleja una relación negativa significativa con el valor estacional de hace 12 meses (un año). El signo negativo indica que la estacionalidad en ese periodo tiene un efecto opuesto al valor actual.

SMA Coefficients (sma1):

sma1 = -0.3906: Este coeficiente muestra un impacto negativo de los errores estacionales de un año atrás (12 meses). Indica que el error de ese periodo tiene un efecto considerablemente negativo sobre el valor actual de la serie.

Estadísticas del Modelo

Sigma² (Varianza del error): 49.32. Indica la varianza de los errores del modelo. Un valor relativamente bajo sugiere que el modelo está capturando bien la variabilidad de la serie, aunque aún existe algo de error no explicado.

Log Likelihood: -946.87. Un valor negativo de log-verosimilitud indica que el modelo no es el modelo de máxima verosimilitud, pero debe compararse con otros modelos para evaluar la calidad del ajuste.

AIC (Criterio de Información de Akaike): 1907.74. El AIC penaliza la complejidad del modelo, por lo que valores más bajos son mejores. Este valor debe compararse con otros modelos para identificar el mejor ajuste.



ME (Error Medio): 0.3642384. El error medio positivo indica que el modelo tiende a sobrestimar ligeramente los valores, aunque el valor es pequeño, lo que sugiere que la predicción está bastante cerca del valor real.

Métricas de Error

RMSE (Raíz del Error Cuadrático Medio): 6.852828. El RMSE es una medida de la magnitud promedio de los errores, expresada en las mismas unidades que los datos originales. Valores bajos indican un buen ajuste del modelo, aunque este valor puede sugerir que hay algo de error sin capturar en el modelo.

MAE (Error Absoluto Medio): 3.958629. Esta métrica muestra el promedio de los errores absolutos entre las predicciones y los valores reales. Es una medida de la precisión, y el valor relativamente bajo indica un buen rendimiento general del modelo.

MPE (Error Porcentual Medio): 0.1706179. Este valor sugiere que el modelo presenta un sesgo ligeramente positivo, ya que los errores de predicción tienden a sobrestimar un poco los valores en promedio, aunque el sesgo es pequeño.

MAPE (Error Porcentual Absoluto Medio): 3.700246. Este valor indica que, en promedio, el modelo tiene un error porcentual de alrededor del 3.7%, lo cual es relativamente bajo, sugiriendo que el modelo es bastante preciso en términos relativos.

MASE (Error Absoluto Medio Escalado): 0.4929295. Un valor de MASE cercano a 1 o menor indica que el modelo está haciendo un buen trabajo en comparación con un modelo de referencia naïve. Este valor sugiere que el modelo tiene un rendimiento adecuado, ya que es menor que 1.

ACF1 (Función de Autocorrelación en el Lag 1): -0.00314043. Este valor cercano a cero indica que no hay autocorrelación significativa en el primer lag de los residuos del modelo, lo que es una buena señal, ya que significa que los errores no muestran patrones temporales significativos no capturados por el modelo.

Tabla 3. Criterio de información de Akaike (AIC) y el Criterio de información bayesiano (BIC).

Modelo	AIC	BIC
ARIMA	2185.692	2204.059
SARIMA	1907.739	1933.157

En la tabla 3, dado que tanto el AIC como el BIC son menores para el modelo SARIMA en comparación con el modelo ARIMA, podemos concluir que:

El modelo SARIMA se ajusta mejor a los datos que el modelo ARIMA, tanto en términos de calidad de ajuste (AIC) como de parsimonia (BIC).

Tabla 4. Predicción de las remesas del 2025 al 2027 (3 años)

Fecha	Meses	Pronóstico	Límite_Inferior_80	Límite_Superior_80	Límite_Inferior_95	Límite_Superior_95
2025	Enero	471.4659	446.4138	496.518	433.152	509.7798
2025	Febrero	481.672	454.7068	508.6373	440.4323	522.9118
2025	Marzo	514.6703	485.8593	543.4814	470.6076	558.733
2025	Abril	537.2036	506.6056	567.8015	490.4081	583.9991
2025	Mayo	567.4938	535.1611	599.8264	518.0452	616.9423
2025	Junio	553.7602	518.2671	589.2534	499.4781	608.0423
2025	Julio	566.1357	528.0531	604.2183	507.8935	624.3779
2025	Agosto	575.9641	535.1615	616.7668	513.5618	638.3664
2025	Septiembre	568.5908	525.1832	611.9984	502.2046	634.9769
2025	Octubre	587.3994	541.4223	633.3766	517.0835	657.7154
2025	Noviembre	576.9659	528.4819	625.45	502.816	651.1159
2025	Diciembre	605.1549	554.2148	656.095	527.2487	683.0611
2026	Enero	568.1481	514.8028	621.4935	486.5635	649.7328
2026	Febrero	578.6627	522.9585	634.3669	493.4704	663.8549
2026	Marzo	611.1184	553.0983	669.1385	522.3843	699.8525
2026	Abril	638.6934	578.3967	698.99	546.4776	730.9092
2026	Mayo	666.9547	604.4175	729.492	571.3123	762.5971
2026	Junio	655.0903	588.9264	721.2542	553.9014	756.2793
2026	Julio	667.7452	598.4429	737.0475	561.7564	773.7339
2026	Agosto	678.5305	605.9261	751.1349	567.4916	789.5693
2026	Septiembre	671.7989	595.9745	747.6233	555.8355	787.7623
2026	Octubre	691.443	612.4086	770.4774	570.5703	812.3157
2026	Noviembre	681.7482	599.5465	763.95	556.0315	807.465
2026	Diciembre	710.6269	625.2927	795.9611	580.1196	841.1342
2027	Enero	674.7023	586.2743	763.1303	539.4634	809.9412
2027	Febrero	685.8892	594.404	777.3744	545.9746	825.8038
2027	Marzo	719.1525	624.6456	813.6595	574.6166	863.6885
2027	Abril	746.6487	649.1535	844.144	597.5426	895.7549
2027	Mayo	775.9538	675.5016	876.4059	622.3255	929.5821
2027	Junio	764.5143	659.9194	869.1092	604.5502	924.4784
2027	Julio	777.8465	669.5035	886.1895	612.1502	943.5427
2027	Agosto	789.2016	676.9621	901.4411	617.5462	960.8571
2027	Septiembre	783.0899	667.0152	899.1647	605.5689	960.611
2027	Octubre	803.3231	683.4145	923.2318	619.9387	986.7076
2027	Noviembre	794.2328	670.5212	917.9445	605.0323	983.4334




En la tabla 4, el pronóstico muestra un aumento general en las remesas, pasando de aproximadamente 471.5 millones en enero de 2025 a 803.3 millones en octubre de 2027. Para cada mes, se presentan los límites de confianza al 80% y 95%, lo que proporciona un rango esperado para las remesas.

Para enero de 2025, el pronóstico es de 471.5 millones con un límite inferior al 80% de 446.4 millones y superior de 496.5 millones, mientras que el intervalo de confianza al 95% oscila entre 433.2 millones y 509.8 millones. La media de remesas en el periodo 2025-2027 se sitúa en torno a los 643 millones de dólares mensuales, reflejando una tendencia de crecimiento que se sostiene en los tres años. Sumando los pronósticos mensuales, el total de remesas proyectadas para este periodo alcanza aproximadamente 23,148 millones de dólares en estos tres años.

La predicción indica una tendencia positiva en las remesas con un crecimiento estable. La fluctuación en los límites inferiores y superiores es baja en el corto plazo, pero se amplía hacia 2027, reflejando mayor incertidumbre en los pronósticos a largo plazo.

Figura 8. Análisis técnico de las predicciones



En la figura 8 muestra la evolución de las remesas en Nicaragua desde el año 2000 hasta una proyección para el año 2027.

La proyección para los próximos años sigue indicando un incremento continuo en las remesas. Según las líneas de tendencia, se espera que estas superen los 900 millones de dólares para el año 2027. La amplitud de estas bandas sugiere que, aunque se espera un crecimiento, hay incertidumbre sobre la magnitud exacta del incremento.

Dado el amplio intervalo de confianza, hay una posibilidad de que las remesas crezcan más rápido o más lento de lo anticipado, esto implica que factores imprevistos como cambios en políticas migratorias o condiciones económicas en países emisores de remesas (EE. UU., España, etc.) podrían alterar significativamente las proyecciones.



IX. CONCLUSIÓN

Las remesas en Nicaragua han mostrado un crecimiento sostenido desde el año 2000. En 2023, las remesas alcanzaron aproximadamente 4,000 millones de dólares. Esta cifra representa un aumento significativo desde menos de 100 millones de dólares en el año 2000.

El modelo SARIMA ofreció un mejor ajuste en comparación con ARIMA debido a su capacidad para manejar la estacionalidad en las remesas. La precisión del SARIMA se reflejó en intervalos de confianza más estrechos y una mejor capacidad para captar tendencias estacionales recurrentes.

Para 2025, el pronóstico central proyecta que las remesas podrían llegar a aproximadamente 610 millones de dólares, con un intervalo de confianza del 95% y un error del 5% que sugirió un rango entre 520 millones y 680 millones. Para 2026, se espera que las remesas alcancen entre 550 millones y 890 millones de dólares.

En conclusión, para noviembre de 2027, el pronóstico central indica que las remesas podrían superar los 700 millones de dólares, con un límite superior de cercano a 1,000 millones de dólares.



X. RECOMENDACIONES

- Fomentar el uso de herramientas como el software R y la inclusión de datos reales en actividades prácticas para mejorar la comprensión y el análisis predictivo.
- Las entidades bancarias y de remesas pueden utilizar estos modelos para optimizar sus proyecciones de flujo de efectivo, adaptando sus estrategias de servicio según las tendencias previstas.
- Proponer proyectos que incentiven la inversión productiva de remesas en pequeñas empresas o actividades económicas locales, aumentando la autosuficiencia de las comunidades receptoras.
- Ampliar el uso de modelos predictivos para analizar posibles fluctuaciones en las remesas debido a eventos externos, como crisis económicas globales, y así establecer medidas preventivas.
- Implementar análisis comparativos entre distintos modelos predictivos para evaluar el impacto de la estacionalidad o eventos atípicos en las proyecciones.
- Explorar el uso de algoritmos de aprendizaje automático (machine learning) para predecir comportamientos de remesas, especialmente en escenarios con alta volatilidad.
- Incentivar la realización de estudios longitudinales que evalúen cómo las remesas afectan variables macroeconómicas específicas, como el consumo, la inversión o la desigualdad.

XI. CRONOGRAMA DE ESTUDIO

Semanas	Estatus	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Semana 8	Semana 9	Semana 10	Semana 11	Semana 12	Semana 13	Semana 14	Semana 15	Semana 16	Semana 17	Semana 18	Semana 19	Semana 20	Semana 21	Semana 22	Semana 23	Semana 24	Semana 25	Semana 26	Semana 27	Semana 28	Semana 29	Semana 30	Semana 31	Semana 32	Semana 33	
Actividades semanales																																			
Selección del tema	Revisado																																		
Introducción	Revisado																																		
Planteamiento del problema	Revisado																																		
Justificación	Revisado																																		
Antecedentes	Revisado																																		
Elaboración de los objetivos	Revisado																																		
Marco teórico	Revisado																																		
Marco conceptual	Revisado																																		
Metodología	Revisado																																		
Resultados	Revisado																																		
Conclusión	Revisado																																		
Referencia bibliográfica	Revisado																																		

XII. ANEXOS

BANCO CENTRAL DE NICARAGUA (BCN)

Remesas mensuales

(Millones de dólares)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
2000	19.8	20.8	23.4	23.6	24.8	25.2	26.3	27.5	29.4	29.9	29.5	39.8	320.0
2001	25.1	24.7	27.3	26.2	27.6	25.2	27.4	30.4	29.5	30.9	27.3	34.1	335.7
2002	30.3	29.0	32.1	32.0	33.5	29.3	29.1	30.0	32.8	33.8	29.4	35.2	376.5
2003	33.5	31.8	35.6	33.0	36.2	33.2	36.4	38.1	39.6	38.1	38.2	45.1	438.8
2004	38.0	37.2	42.3	40.0	43.4	41.5	43.2	43.0	48.9	47.9	46.1	47.3	518.8
2005	51.4	49.5	52.7	48.8	52.3	47.8	49.8	48.6	52.1	49.5	50.8	62.4	615.7
2006	57.8	54.6	61.2	54.7	60.2	53.6	57.1	58.1	63.4	61.2	52.9	62.7	697.5
2007	51.4	52.6	61.1	57.3	63.9	59.9	61.8	65.2	62.7	66.5	65.7	71.5	739.6
2008	60.8	63.4	71.5	67.7	73.6	66.8	66.9	69.5	70.8	67.5	66.1	73.5	818.1
2009	62.7	62.8	70.4	62.5	66.2	62.1	61.3	60.7	62.2	64.4	61.9	71.2	768.4
2010	60.7	64.1	77.0	63.8	70.2	63.5	66.5	66.5	67.9	70.3	70.6	81.7	822.8
2011	67.4	69.3	77.5	73.4	77.8	70.0	74.5	77.3	74.8	79.4	75.7	94.5	911.6
2012	78.1	82.3	89.7	80.1	85.2	78.9	80.9	82.4	82.9	87.3	82.8	103.6	1,014.2
2013	83.4	83.7	90.2	90.7	92.7	80.9	86.6	88.6	90.5	90.3	89.1	111.0	1,077.7
2014	85.6	90.0	101.6	91.1	98.5	88.4	92.6	92.2	94.7	93.5	91.0	116.6	1,135.8
2015	88.9	94.1	106.2	94.4	104.9	93.1	97.6	96.6	98.7	102.6	95.7	120.6	1,193.4
2016	91.2	103.4	107.7	103.5	107.4	95.5	98.7	107.9	106.3	108.1	104.3	130.1	1,264.1
2017	102.1	107.6	113.6	108.4	121.2	111.1	122.4	120.4	112.8	118.5	116.0	136.7	1,390.8
2018	112.9	116.9	123.6	128.9	127.1	115.2	124.4	126.7	121.7	128.9	125.4	149.5	1,501.2
2019	124.2	122.3	137.3	134.5	144.0	134.3	146.2	145.5	139.1	144.6	144.2	166.2	1,682.4
2020	139.2	143.8	141.5	122.2	159.2	154.7	162.4	163.0	156.7	165.5	152.3	190.9	1,851.4
2021	156.1	153.6	190.7	170.8	187.1	171.9	176.6	174.8	175.7	189.3	186.6	213.7	2,146.9
2022	194.7	202.2	235.7	233.9	266.0	263.7	274.4	299.7	288.1	319.9	309.5	337.1	3,224.9
2023	317.0	330.6	372.7	374.3	426.2	394.2	408.9	409.8	399.8	410.9	395.4	420.3	4,660.1
2024	366.8	374.5	399.6	449.4	462.4								2,052.7

Fuente: BCN.



Acceso a la base de datos para generar resultados:

<https://docs.google.com/spreadsheets/d/1FjPfzGdxRHFXYDEupoOtYZIC133oxfCQ/edit?rtfpof=true&sd=true&gid=1953613749#gid=1953613749>

Códigos en R para los resultados:

```
library(tseries)

--library(lubridate)

library(tidyverse)

library(forecast)

library(ggplot2)

library(readxl)

# Cargar datos de remesas

remesas <- read_excel('remesas.xlsx')

View(remesas)

attach(remesas)

# Convertir los datos en una serie temporal

remesas.ts <- ts(remesas, start = c(2000,1), frequency = 12)

print(remesas.ts)

# 1. Análisis Exploratorio de Datos (EDA)

# Gráfico de la serie temporal con todos los años

p1 <- autoplot(remesas.ts) +

  ggtitle("Remesas recibidas en millones de dólares") +

  xlab("Año") + ylab("Remesas") +

  theme_minimal() +

  scale_x_continuous(breaks = seq(2000, 2024, by = 1))

print(p1)
```



```
# Estacionariedad: Número de diferencias requeridas

ndiffs_value <- ndiffs(remesas.ts)

print(paste("Número de diferencias requeridas:", ndiffs_value))

# ACF y PACF en la serie original

p3 <- ggAcf(remesas.ts) + ggtitle("ACF - Serie No Estacionaria")

p4 <- ggPacf(remesas.ts) + ggtitle("PACF - Serie No Estacionaria")

print(p3)

print(p4)

# Diferenciación de la serie

remesas_diff <- diff(remesas.ts, differences = ndiffs_value)

print(remesas_diff)

p5 <- autoplot(remesas_diff) +

  ggtitle("Serie Diferenciada de Remesas") +

  xlab("Año") + ylab("Diferencias de Remesas") +

  theme_minimal()

print(p5)

# ACF y PACF de la serie diferenciada

p6 <- ggAcf(remesas_diff) + ggtitle("ACF - Serie Estacionaria")

p7 <- ggPacf(remesas_diff) + ggtitle("PACF - Serie Estacionaria")

print(p6)

print(p7)

# Descomposición de la serie temporal

descomposicion <- decompose(remesas.ts)

p8 <- autoplot(descomposicion) +

  ggtitle("Descomposición de la Serie Temporal") +
```



```
theme_minimal()

print(p8)

# 2. Modelación de series temporales

# a. Modelo ARIMA manual

p <- 2

d <- ndiffs_value

q <- 2

modelo_arima <- arima(remesas.ts, order = c(p, d, q))

print(summary(modelo_arima))

# b. Modelo SARIMA manual

P <- 1

D <- 1

Q <- 1

s <- 12

modelo_sarima <- arima(remesas.ts, order = c(p, d, q), seasonal = list(order = c(P, D, Q), period = s))

print(summary(modelo_sarima))

modelos_comparacion <- data.frame(

  Modelo = c("ARIMA", "SARIMA"),

  AIC = c(AIC(modelo_arima), AIC(modelo_sarima)),

  BIC = c(BIC(modelo_arima), BIC(modelo_sarima))

)

print(modelos_comparacion)

# Definir el horizonte de predicción

horizonte <- 42
```



```
pronostico <- forecast(modelo_sarima, h = horizonte)

print(pronostico)

# Crear gráfico del pronóstico

library(forecast)

autoplot(pronostico, main = "Pronóstico de Remesas en Nicaragua") +

  xlab("Año") + ylab("Remesas") +

  scale_x_continuous(breaks = seq(2000, 2027, by = 1)) +

  autolayer(pronostico$mean, series = "Pronóstico", color = "black") +

  autolayer(pronostico$lower[,2], series = "Límite Inferior 95%", color = "blue") +

  autolayer(pronostico$upper[,2], series = "Límite Superior 95%", color = "red") +

  autolayer(pronostico$lower[,1], series = "Límite Inferior 80%", color = "green") +

  autolayer(pronostico$upper[,1], series = "Límite Superior 80%", color = "white") +

  ggtitle(expression(paste("Pronóstico de Remesas en Nicaragua"))) + # Título con expresión LaTeX

  theme(plot.title = element_text(hjust = 0.5)) + # Centrar el título

  scale_y_continuous(

    breaks = seq(100, 1000, by = 100), # Ajusta los valores de las etiquetas en el eje Y

    limits = c(100, 1000), # Define el rango del eje Y

    name = "Escala de Remesas"

  )

)
```



XIII. BIBLIOGRAFIA

1. Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
2. Adams, R. H., & Cuecuecha, A. (2013). The impact of remittances on investment and poverty in Ghana. *World Development*, 50, 24–40. <https://doi.org/10.1016/j.worlddev.2013.04.009>
3. Banco Central de Nicaragua. (2020). Informe anual de remesas. https://www.bcn.gob.ni/publicaciones/periodicidad/anual/remesas_anuales/
4. Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
5. Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2016). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
6. Brockwell, P. J., & Davis, R. A. (2016). *Introduction to time series and forecasting* (3rd ed.). Springer.
7. Burnham, K. P., & Anderson, D. R. (2004). *Model selection and multimodel inference: A practical information-theoretic approach* (2nd ed.). Springer.
8. Chami, R., Fullenkamp, C., & Jahjah, S. (2005). Are immigrant remittance flows a source of capital for development? *IMF Staff Papers*, 52(1), 55–81.
9. Chatfield, C. (2004). *The analysis of time series: An introduction*. Chapman and Hall/CRC.
10. Chatfield, C. (2016). *The analysis of time series: An introduction* (7th ed.). CRC Press.
11. Chatfield, C. (2019). *The analysis of time series: An introduction* (6th ed.). Chapman and Hall/CRC.
12. Chinlli, C. M. (s. f.). *Modelización de series temporales: Modelos clásicos y SARIMA*.
13. Diebold, F. X. (2015). *Forecasting in economics, business, finance and beyond*. Princeton University Press.
14. Enders, W. (2014). *Applied econometric time series* (4th ed.). Wiley.



15. Franses, P. H. (1998). Time series models for business and economic forecasting. Cambridge University Press.
16. Fuller, W. A. (1996). Introduction to statistical time series (2nd ed.). Wiley.
17. García, R. (2020). Las remesas como motor de desarrollo local en Nicaragua. Universidad Nacional Autónoma de Nicaragua.
18. García Díaz, J. C. (2011). Series temporales, análisis y predicción: Ejercicios prácticos. Universidad Politécnica de Valencia. <https://koha.indo.edu.mx/cgi-bin/koha/opac-detail.pl?biblionumber=282143>
19. González, P. (2021). Análisis y predicción de las remesas en Costa Rica: Un enfoque de series temporales (Tesis de licenciatura). Universidad de Costa Rica.
20. Granger, C. W. J., & Newbold, P. (2014). Forecasting economic time series. Academic Press.
21. Greene, W. H. (2018). Econometric analysis (8th ed.). Pearson.
22. Hamilton, J. D. (1994). Time series analysis. Princeton University Press.
23. Harvey, A. C. (1990). The econometric analysis of time series (2nd ed.). MIT Press.
24. Hernández, L. (2020). Predicción de las remesas hacia Guatemala mediante modelos ARIMA (Tesis de licenciatura). Universidad de San Carlos de Guatemala.
25. Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and practice (2nd ed.). OTexts.
26. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning: With applications in R. Springer.
27. Koop, G. (2006). Analysis of economic data (3rd ed.). Wiley.
28. Lutkepohl, H. (2005). New introduction to multiple time series analysis. Springer.
29. Martínez, R. (2019). Pronóstico de las remesas hacia El Salvador y su impacto en la economía nacional (Tesis de licenciatura). Universidad de El Salvador.
30. Mills, T. C. (2019). Time series techniques for economists. Cambridge University Press.
31. Ratha, D. (2013). The impact of remittances on economic growth and poverty reduction. In Migration and remittances factbook 2013. World Bank.



32. Rodríguez, L. (2019). Las remesas y el acceso a servicios de salud en Nicaragua. Universidad Nacional Autónoma de Nicaragua.
33. Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics*, 6(2), 461–464.
34. Shumway, R. H., & Stoffer, D. S. (2017). *Time series analysis and its applications: With R examples* (4th ed.). Springer.
35. Tsay, R. S. (2010). *Analysis of financial time series* (3rd ed.). Wiley.
36. Tukey, J. W. (1977). *Exploratory data analysis*. Addison-Wesley.
37. Wei, W. W. (2019). *Time series analysis: Univariate and multivariate methods* (2nd ed.). Addison-Wesley.
38. Wooldridge, J. M. (2016). *Introductory econometrics: A modern approach* (6th ed.). Cengage Learning.
39. World Bank. (2011). *Migration and remittances factbook 2011*. World Bank.
40. Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice*. OTexts.