

Pronóstico de morosidad de cartera vencida aplicando series temporales

Forecasting delinquency of overdue loans using time series analysis

Cristina Monserrateh Ibarra Gallo*

Universidad Nacional de Chimborazo.
Riobamba-Ecuador.
cristina.ibarra@unach.edu.ec
<https://orcid.org/0009-0006-8574-4106>

Marco Antonio Daqui Janeta

Universidad Nacional de Chimborazo.
Riobamba-Ecuador.
mdaqui@unach.edu.ec
<https://orcid.org/0009-0008-4274-2500>

***Correspondencia:**

cristina.ibarra@unach.edu.ec

Cómo citar este artículo:

Ibarra, C., & Daqui, M. (2025). Pronóstico de morosidad de cartera vencida aplicando series temporales. *Esprint Investigación*, 4(1), 102-117. <https://doi.org/10.61347/ei.v4i1.98>

Recibido: 29 de diciembre de 2024

Aceptado: 30 de enero de 2025

Publicado: 4 de febrero de 2025

Resumen: El pronóstico de morosidad resulta fundamental para la gestión del riesgo crediticio, ya que permite identificar y anticipar áreas con alta probabilidad de incumplimiento. Al prever estos riesgos, las instituciones pueden implementar medidas preventivas y estrategias de mitigación. Esta investigación se enfoca en el pronóstico de morosidad de cartera vencida mediante el uso de series temporales, un aspecto esencial en la contabilidad financiera de las entidades bancarias. El presente estudio analiza el pronóstico de morosidad de cartera vencida en una cooperativa de ahorro y crédito de la ciudad de Riobamba. Para ello, se empleó un enfoque cuantitativo para analizar el pronóstico de morosidad de cartera vencida aplicando técnicas de series temporales. Se adoptó un diseño no experimental, centrado en la recopilación y análisis de datos históricos con un enfoque longitudinal. A través de este estudio, se examinó la evolución de la morosidad y se desarrollaron modelos predictivos para identificar patrones y tendencias en la cooperativa. Los resultados muestran que las técnicas de pronóstico basadas en series temporales, como los modelos ARIMA, son efectivas para generar predicciones precisas sobre la morosidad de cartera vencida. Además, el análisis reveló variaciones significativas con tendencia decreciente en la morosidad de la cartera de consumo, así como un incremento en la cartera de microcrédito y en la morosidad de cartera total.

Palabras clave: Cartera vencida, gestión del riesgo, morosidad, pronóstico, series temporales.

Abstract: The delinquency forecast is fundamental for credit risk management, as it allows identifying and anticipating areas with a high probability of default. By anticipating these risks, institutions can implement preventive measures and mitigation strategies. This research focuses on forecasting delinquency of past-due loans using time series, an essential aspect in the financial accounting of banking institutions. This study analyzes the delinquency forecast of past-due loans in a savings and credit cooperative in the city of Riobamba. For this purpose, a quantitative approach was used to analyze the delinquency forecast of past-due loans by applying time series techniques. A non-experimental design was adopted, focused on the collection and analysis of historical data with a longitudinal approach. Through this study, the evolution of delinquency was examined, and predictive models were developed to identify patterns and trends in the cooperative. The results show that time-series based forecasting techniques, such as ARIMA models, are effective in generating accurate predictions of delinquent loan portfolio delinquency. In addition, the analysis revealed significant variations with a decreasing trend in consumer portfolio delinquency, as well as an increase in the microcredit portfolio and in total portfolio delinquency.

Keywords: Delinquency, forecasting, overdue portfolio, risk management, time series.

Copyright: Derechos de autor 2025 Cristina Monserrateh Ibarra Gallo, Marco Antonio Daqui Janeta.



Esta obra está bajo una licencia internacional Creative Commons Atribución-NoComercial 4.0.

1. Introducción

La gestión de la morosidad de cartera vencida resulta fundamental para las instituciones financieras y empresas que otorgan créditos, ya que prever con precisión los niveles de morosidad mantiene la estabilidad financiera, optimiza recursos y mitiga riesgos. La falta de herramientas predictivas puede llevar a decisiones subóptimas, agravando crisis económicas y afectando la estabilidad financiera global (Cerqueira et al., 2020).

El sector financiero impulsa el crecimiento económico de los países y uno de los principales aspectos para tener en cuenta en las instituciones es una eficiente gestión financiera. Se define el término cartera como un grupo de activos que posee un inversor o una sociedad de inversión y que incluyen instrumentos financieros como acciones, bonos, materias primas o derivados (Mosso & López-Herrera, 2019). Sin embargo, este sector puede deteriorarse en tiempos de crisis y la mayoría de las veces está asociado con préstamos morosos (Morales et al., 2022). La principal dificultad que enfrentan las empresas financieras debido a la acumulación de cuentas por cobrar es la falta de liquidez.

La cartera vencida se origina cuando los prestatarios no cumplen con los pagos de sus créditos dentro del tiempo acordado. Según Murillo-Robles & Palacios-Cedeño (2022), la cartera vencida se define como aquellos créditos o préstamos cuyos pagos de interés y capital están atrasados por 90 días o más, siendo uno de los indicadores más comunes para medir el riesgo de una cartera crediticia. Esta situación puede generar una presión significativa sobre el flujo de caja de las empresas, limitando su capacidad para operar de manera eficiente y para invertir en nuevas oportunidades de crecimiento.

En este contexto, la Junta de la Política y Regulación Monetaria y Financiera (2015) mediante resolución No. 129-2015F expidió la Norma para la Gestión del Riesgo de Crédito en las Cooperativas de Ahorro y Crédito y Asociaciones Mutualistas de Ahorro y Crédito para la Vivienda. Esta normativa tiene como objetivo definir los aspectos mínimos a considerar para la gestión del riesgo de crédito. En ella, se define la cartera vencida como “la parte del saldo del capital de la cartera de crédito que reporta retrasos en el cumplimiento de sus obligaciones de pago” (p. 3). Esta situación implica un incumplimiento, entendido como “no cumplir la obligación dentro del plazo estipulado; o hacerlo después de dicho plazo, o en condiciones diferentes a las pactadas” (p. 3).

Ante esta situación, las cooperativas de ahorro y crédito dedican gran parte de su tiempo en trazar políticas que orienten de forma precisa cada una de sus actividades con el propósito de asegurar el retorno del capital prestado al tiempo pactado, de tal forma que se cumpla lo planificado y responda a los intereses de sus directivos y socios en general (Cedeño-Jaramillo & Zambrano-Montesdeoca, 2022). Las estrategias actuales no son completamente efectivas, ya que no logran que los clientes que tienen cartera vencida regularicen sus pagos. Esto se debe a que las empresas carecen de sistemas de información apropiados para gestionar adecuadamente estas cuentas. Además, no llevan un registro preciso del tiempo que los clientes permanecen en mora en relación con los términos de pago establecidos en los contratos (Rubio, 2021).

Por otro lado, las cooperativas enfrentan varios desafíos en la gestión de la morosidad, como la falta de seguimiento efectivo de los préstamos vencidos, los problemas económicos de los deudores, la ausencia de incentivos para la recuperación y los costos asociados con los procesos legales (Toalombo-Villa & Cárdenas-Pérez, 2023). Por ende, el pronóstico de morosidad es esencial para la gestión efectiva del riesgo crediticio. Al identificar y prever las áreas donde es probable que ocurran incumplimientos, la institución puede implementar medidas preventivas y estrategias de mitigación adecuadas. Esto incluye ajustes en las políticas de crédito, asignación de recursos para la recuperación de deudas y cálculo de provisiones para cubrir posibles pérdidas.

El pronóstico de morosidad de cartera vencida aplicando series temporales es un aspecto crucial en la contabilidad financiera de instituciones bancarias. Su importancia radica en su capacidad para proporcionar una visión precisa y proyectada de los posibles incumplimientos de pago por parte de los clientes. Esta anticipación permite a la institución prepararse para enfrentar posibles pérdidas asociadas con la morosidad (Deras et al., 2023).

En consecuencia, deben emplearse modelos avanzados para el pronóstico de la morosidad de cartera vencida en instituciones financieras. Por ejemplo, Noriega et al. (2023) proporcionan una revisión de las técnicas de Deep Learning (DL) más utilizadas para la previsión de series temporales. Los autores resaltan que la aplicación de arquitecturas actuales de DL en series temporales mejora la precisión del pronóstico de morosidad, ayudando a las instituciones financieras a gestionar el riesgo.

Por su parte, Kader et al. (2023) revisan el uso del algoritmo de DL llamado Long Short-Term Memory Approach (LSTM) para el análisis y la previsión de series temporales, y subrayan sus beneficios en la captura de dependencias a largo plazo en los datos, esencial para pronosticar eventos financieros como la morosidad de los préstamos y la previsión de la oferta y la demanda. Los investigadores destacan a LSTM como una técnica de Machine Learning de vanguardia que optimiza la capacidad de predecir eventos financieros complejos, al proporcionar a los analistas herramientas más robustas para la previsión de morosidad.

Lim & Zohren (2021) examinan las arquitecturas de DL utilizadas para la previsión de series temporales en diferentes dominios, con un enfoque en los modelos híbridos más recientes. Se discute las mejoras en la precisión y eficiencia de los pronósticos debido al avance en los modelos de Machine Learning, al ofrecer pronósticos precisos y fiables en múltiples sectores, y al facilitar a las instituciones la toma de decisiones informadas. Además, describe algunas formas en las que el aprendizaje profundo también posibilita el apoyo a la toma de decisiones con datos de series temporales.

Asimismo, Miller et al. (2024) destacan las ventajas de los modelos híbridos de Machine Learning y técnicas estadísticas tradicionales, conocidos como Makridakis (M). Estas mostraron un rendimiento superior en la previsión de series temporales, convirtiéndose en las mejores. En dicha encuesta, se revisan las técnicas de modelado de última generación combinando la precisión de los modelos de DL con la robustez de las técnicas estadísticas.

Cerqueira et al. (2020), quienes comparan métodos de estimación del rendimiento en tareas de predicción de series temporales, recalcan la importancia de estimar la pérdida que un modelo predictivo incurrirá en datos no vistos, y cómo esta estimación es fundamental en proyectos de Machine Learning. Además, se aborda la dependencia entre observaciones en series temporales y se mencionan los enfoques más comunes, como la validación cruzada. La correcta evaluación de los modelos de pronóstico garantiza la precisión y fiabilidad de las predicciones de morosidad de préstamos. Este estudio proporciona un marco robusto para seleccionar y validar modelos estadísticos, mejorando así la capacidad predictiva y la toma de decisiones financieras.

Los problemas crediticios que enfrenta Ecuador actualmente son serios e importantes. Debido al creciente deterioro de la cartera de crédito en instituciones financieras, el sistema financiero nacional tiende a desestabilizarse. Además, los múltiples desempleos y cierre de negocios han acelerado el índice de morosidad y afectado la situación económica (Vallejo et al., 2021). Una de las principales causas de la morosidad es la rápida expansión del crédito. Según Contreras (2021), las entidades financieras enfrentan una lucha constante por obtener la mayor cuota del mercado, y conceder créditos a clientes con poca calidad crediticia es la manera más sencilla de ganarla.

Aun así, el sector de las microfinanzas es considerado un campo atractivo y en los últimos años ha tenido un crecimiento exponencial. Una estrategia adoptada por las empresas para captar clientes debido al incremento de la competencia es otorgar ciertas flexibilidades, que afecta a los indicadores crediticios primordiales para la buena gestión (Ronquillo, 2020). Las cooperativas de ahorro y crédito dependen de la solvencia y puntualidad de los pagos de sus miembros para mantener una cartera de préstamos saludable. La existencia de una relación de largo plazo entre la morosidad y el deterioro de la cartera podrían indicar un mayor riesgo de desgaste en sus activos (Mosso & López-Herrera, 2019).

Una cooperativa de ahorro y crédito ubicada en la ciudad de Riobamba, Ecuador, enfrenta dificultades para predecir la morosidad de manera precisa mediante metodologías tradicionales. La morosidad de la cartera vencida puede afectar directamente los indicadores de desempeño. La necesidad de adoptar un enfoque basado en series temporales para pronosticar la morosidad se hace evidente, pero existen barreras en términos de conocimientos técnicos, integración de datos y adaptación de modelos predictivos a las características específicas de la cartera.

En este contexto, la presente investigación tiene como objetivo pronosticar la morosidad de cartera vencida aplicando series temporales en la cooperativa de ahorro y crédito. Para ello, es necesario describir las técnicas de pronóstico basadas en series temporales para la morosidad de cartera vencida, seleccionar y preprocesar los datos de cartera vencida de la entidad, e identificar los patrones de pronóstico observados en los datos de cartera vencida desde una perspectiva contable.

2. Metodología

El presente estudio adoptó un enfoque cuantitativo para analizar el pronóstico de morosidad de cartera vencida aplicando técnicas de series temporales. Se utilizó un diseño no experimental enfocado en la recopilación y análisis de datos históricos con corte longitudinal. Este diseño permitió examinar la evolución de la morosidad a lo largo del tiempo y desarrollar modelos predictivos para identificar patrones y tendencias. La metodología se centró en la aplicación de técnicas estadísticas avanzadas para el análisis de series temporales, con el objetivo de proporcionar pronósticos precisos y útiles para la gestión de riesgos financieros.

La población del estudio estuvo constituida por la información financiera de la cooperativa de ahorro y crédito con registros de morosidad en su cartera vencida. El periodo de análisis abarcó desde 2021 hasta 2024 e incluyó tendencias y patrones de morosidad. Los datos fueron extraídos y preprocesados para asegurar la calidad y consistencia de la información utilizada en el análisis.

Con el propósito de describir las técnicas de pronóstico basadas en series temporales, se empleó un enfoque bibliográfico mediante la técnica de análisis documental, fundamentado en fuentes confiables como artículos científicos y libros. El procedimiento seguido consistió en: (1) identificar los modelos utilizados para el análisis de series de tiempo, (2) describir los modelos comúnmente empleados para el pronóstico, tales como Suavizamiento Exponencial, ARIMA, SARIMA, así como técnicas de Machine Learning y DL.

Para seleccionar y procesar los datos de cartera vencida de la entidad se empleó un método empírico mediante la técnica de selección y procesamiento utilizando una base de datos. El procedimiento realizado incluyó: (1) la recopilación de datos históricos, (2) el análisis de la calidad de los datos obtenidos, (3) la selección de las variables de interés para el estudio, y (4) la preparación de los datos para el modelo.

Asimismo, en la identificación de los patrones de pronóstico observados en los datos de cartera vencida, se usó un enfoque empírico mediante la técnica de análisis de datos, apoyándose en un

informe de análisis de datos. Los pasos realizados fueron: (1) un análisis exploratorio de los datos, (2) el desarrollo y validación de modelos, (3) la implementación de modelos predictivos con ARIMA, y (4) la identificación y análisis de patrones en los pronósticos.

Finalmente, se utilizó R, un lenguaje diseñado con un enfoque al análisis estadístico y la visualización de datos (Garibaldi et al., 2023), para procesar los datos y desarrollar los modelos predictivos. Además, se empleó el IDE RStudio, uno de los entornos de desarrollo más populares para R, que apoya la investigación reproducible (Giorgi et al., 2022).

3. Resultados

Modelos para el análisis de las series de tiempo

El análisis de series temporales es una técnica fundamental para comprender y prever datos que se recopilan de manera secuencial en el tiempo. Esta metodología permite identificar patrones, tendencias y estacionalidades en los datos, lo cual es esencial para el desarrollo de modelos predictivos precisos. Según Ruiz et al. (2018), una serie de tiempo se define como una secuencia de medidas que describen el comportamiento de cierto sistema a lo largo del tiempo. La predicción de valores futuros es la principal razón para modelar las series temporales. Aunque se enmarca dentro de la estadística, este campo es muy complejo debido a la metodología y vocabulario especializado que utiliza (Abril, 2021).

La predicción basada en series temporales permite a las empresas anticipar tendencias futuras y tomar decisiones informadas en áreas como la planificación y gestión de inventarios (Zhou et al., 2019), la asignación de recursos para servicios basados en la nube (Yadav et al., 2021) y el desarrollo de estrategias de marketing. En el ámbito financiero, la predicción basada en series temporales se maneja para predecir métricas financieras, incluidos los precios de las acciones y las fluctuaciones de los tipos de cambio de divisas (Kimata et al., 2019).

Según Kolambe & Arora (2024), en términos generales, los métodos de predicción de series temporales se clasifican de la siguiente manera: enfoques estadísticos tradicionales, técnicas modernas de aprendizaje automático, enfoques de aprendizaje profundo y métodos híbridos. En la tabla 1 se presentan los métodos de predicción más relevantes, organizados por cada enfoque, lo que facilita la comparación y comprensión de las distintas técnicas disponibles.

Tabla 1

Métodos de predicción

Enfoque	Definición	Métodos
Clásico	Los métodos tradicionales para la predicción de series temporales implican la predicción de valores futuros basados en datos históricos.	Moving Averages
		Exponential Smoothing
		ARIMA
		SARIMA
Machine Learning	Los métodos de predicción de series temporales basados en el aprendizaje automático aprovechan los algoritmos para analizar patrones de datos históricos y hacer predicciones sobre valores futuros.	Linear Regression
		Decision Trees
		Random Forest
		Support Vector Machines (SVM)
		Gradient Boosting

Deep Learning	La predicción de series temporales basadas en el aprendizaje profundo aprovecha las redes neuronales para modelar dependencias temporales complejas en datos secuenciales. Estos métodos sobresalen en la captura de patrones, tendencias y estacionalidad en datos de series temporales, lo que ofrece un enfoque poderoso para predecir valores futuros.	Recurrent Neural Networks (RNN)
		Long Short-Term Memory (LSTM)
		Gated Recurrent Units (GRU)
		Transformer-based Models
Híbridos	Los enfoques híbridos para la predicción de series temporales tienen como objetivo aprovechar las fortalezas de los métodos clásicos, las técnicas de aprendizaje automático (ML) y los enfoques de aprendizaje profundo (DL) para mejorar la precisión y la solidez de las predicciones.	ARIMA-X
		STL
		Ensembling
		Prophet

Nota. Fuente: Kolambe & Arora (2024).

La predicción de series temporales encuentra aplicaciones en diversos campos, incluyendo finanzas, economía, predicción meteorológica, análisis del mercado de valores, predicción del consumo de energía, entre muchos más. En el campo de estudio, algunos de los métodos aplicados para la toma de decisiones empresariales son: Regression Analysis, ARIMA, Exponential Smoothing, Machine Learning models (Ej., LSTM, Random Forest). Por otro lado, los principales métodos utilizados para el análisis de mercados financieros incluyen: Time Series Analysis, GARCH Models, Autoregressive Models, Neural Networks y Monte Carlo Simulation (Kolambe & Arora, 2024). La elección del método más adecuado dependerá de las características específicas de los datos y del objetivo de predicción en cada contexto.

Recopilación de datos históricos y análisis de calidad de datos

La recopilación de datos históricos es una etapa fundamental en el análisis y pronóstico de la morosidad de cartera vencida. Los datos incluyen información sobre el estado financiero, resultados del ejercicio, clasificación de la cartera, posicionamiento y otros indicadores financieros. Adicionalmente, se llevó a cabo un proceso de análisis de calidad para validar que los datos obtenidos fueran relevantes y suficientes para resolver el problema. Se seleccionó las variables objeto de estudio que fueron los índices de morosidad siguientes: morosidad de la cartera de consumo, morosidad de la cartera de microcrédito y morosidad de la cartera total, representados en porcentajes.

Preprocesamiento y análisis exploratorio de datos


El nuevo conjunto de datos fue un archivo.csv que contiene información necesaria para el análisis de la serie temporal. El preprocesamiento aseguró que los datos cumplieran con el formato correcto para ser utilizados por el algoritmo. Esto incluye la normalización y la transformación a un formato adecuado, así como la creación de variables de tiempo. Por otro lado, el análisis permitió explorar y visualizar los datos para identificar patrones, tendencias y relaciones. Esto es particularmente importante en las series temporales, donde se requiere observar estacionalidades y tendencias a lo largo del tiempo.

En la figura 1 se visualiza la evolución temporal de las variables consideradas para el análisis. En la morosidad de cartera de consumo se evidencian fluctuaciones a lo largo del tiempo. Se observa una tendencia creciente desde 2022 hasta mediados de 2023, seguida de una disminución significativa y una posterior estabilización con algunas fluctuaciones hacia 2024. A diferencia de la cartera de consumo, la morosidad en la cartera de microcrédito muestra una tendencia creciente más consistente a lo largo del tiempo. Aunque hay fluctuaciones, el valor de la mora ha ido aumentando de manera

constante desde 2023 hasta 2024. Finalmente, la morosidad de la cartera total muestra una tendencia ascendente moderada desde 2022 hasta 2024, con varias fluctuaciones. Al igual que en los gráficos anteriores, esta gráfica refleja la evolución de la mora, pero en este caso se trata de una visión agregada que incluye tanto la cartera de consumo como la de microcrédito.

Figura 1

Evolución temporal de la morosidad



Nota. La información relacionada al estudio se obtuvo del portal estadístico de la Superintendencia de Economía Popular y Solidaria (SEPS, 2024).

Modelo ARIMA

Los modelos Autoregressive Integrated Moving Average (ARIMA) son la forma básica y más general de las técnicas de predicción de series temporales. Se basan en la idea de transformar las series temporales para que sean estacionarias mediante el proceso de diferenciación. Se puede suponer que la serie temporal es estacionaria si todas sus propiedades estadísticas son constantes a lo largo del tiempo (Deb et al., 2017). El modelo ARIMA combina tres componentes: autorregresión (AR), diferencias integradas (I) y media móvil (MA). La modelización (p, d, q) , donde p es el orden de autorregresión (AR), d es el orden de diferenciación (I) y q es el orden de media móvil (MA) en el modelo estacional, permite describir una serie de observaciones luego de haber sido diferenciadas d veces. El propósito es extraer las posibles fuentes de no estacionariedad y lograr transformar la serie en un proceso de ruido blanco o un proceso puramente aleatorio (Tudela-Mamani et al., 2022).

El modelo ARIMA ha demostrado su buen rendimiento en cuanto a precisión y exactitud al momento de la predicción de datos de series temporales en temas importantes relacionados con economía, negocios y finanzas (Siami-Namini & Namin, 2018). Según Li & Zhou (2024), los modelos

ARIMA han demostrado ser efectivos en la predicción de variables financieras. Los autores proponen una mejora en los métodos de predicción financiera utilizando el modelo ARIMA junto con algoritmos de aprendizaje profundo como LSTM para la predicción de flujos de fondos en mercados de capitales, destacando la importancia de modelos precisos para gestionar el riesgo de liquidez y mejorar la toma de decisiones financieras.

Para asegurar que el modelo de ajuste seleccionado es adecuado para aplicar el método ARIMA, es necesario validar la estacionariedad en los datos. Una serie es estacionaria cuando su media, varianza y auto covarianza son invariables en el tiempo. Para determinar el número de diferencias ordinarias que cada serie temporal requiere para que sea estacionaria, se empleó la siguiente función en R: `ndiffs(serie_temporal)`.

Dicha función busca cuántas veces es necesario diferenciar la serie (restar el valor de un periodo con el del periodo anterior) para eliminar tendencias o estructuras a largo plazo que no son estacionarias. El resultado es un número entero que indica cuántas diferencias aplicar. Según los resultados, la serie de morosidad de cartera de consumo ya es estacionaria en términos de su tendencia, pues la función devuelve un valor 0. Para la serie de morosidad de cartera de consumo y de cartera total se obtuvo un resultado igual a 1, lo que indica que ambas series deberían ser diferenciadas en nivel 1 para lograr estacionariedad.

Sin embargo, después de la diferenciación, se evaluó cada serie nuevamente. Se obtuvo que la morosidad de cartera de microcrédito es la única que logra estacionariedad, a pesar de diferenciar todas las series al menos una vez para eliminar la tendencia. Para llegar a dicha conclusión, se empleó la prueba de Dickey-Fuller Aumentada (ADF), una prueba estadística empleada para determinar si una serie temporal es estacionaria o no. Por lo tanto, para identificar automáticamente el mejor modelo ARIMA en cada serie, se utilizó la siguiente función de R: `auto.arima(serie_temporal)`. Esta función se utiliza para automatizar el proceso de identificación y ajuste de un modelo ARIMA para una serie temporal (tabla 2).

Tabla 2

Resumen de los modelos ARIMA

Variable	Modelo ARIMA	Interpretación
Morosidad de la cartera de consumo	ARIMA (1, 0, 0) con media distinta de cero	Un término AR de primer orden, no se aplica diferenciación, no hay componente de MA. El modelo incluye un término de media constante diferente de 0.
Morosidad de la cartera de microcrédito	ARIMA (1, 1, 0)	Un término AR de primer orden, se aplica una diferenciación, no hay componente de MA.
Morosidad de la cartera total	ARIMA (1, 1, 0) (0, 1, 0) [12]	Un término AR de primer orden, se aplica una diferenciación, no hay componente de MA ordinario. Además, hay un patrón estacional (0,1,0) [12] que se repite anualmente.

Para validar que el modelo ajustado es el adecuado, es decir, que los residuos no presentan autocorrelaciones significativas y se comportan como un ruido blanco, se realizó una evaluación con la prueba de Ljung-Box en los residuos de cada modelo. En general, se obtuvo un p-valor mayor a 0.05, lo que indica que los residuos son independientes y que el modelo para cada serie es apropiado. De igual manera, se obtuvo un diagnóstico visual y estadístico de los residuos del modelo, los cuales

varían alrededor de 0, por lo tanto, el modelo capturó adecuadamente la estructura de la serie temporal original en todas las variables de estudio.


En esta sección se muestran los resultados del pronóstico realizado para las series: morosidad de la cartera de consumo, morosidad de la cartera de microcrédito y la morosidad de la cartera total, para 6 meses futuros. Se definió este período debido a la limitación existente en el número de observaciones. Para un conjunto de datos de 42 meses, un horizonte de pronóstico de 3 a 6 meses suele ser razonable. En general, aumentar el número de meses de pronóstico podría aumentar la incertidumbre y disminuir la precisión del modelo. La incertidumbre en las predicciones aumenta con el horizonte del pronóstico. Esto se debe a que los errores de predicción se acumulan y la capacidad del modelo para capturar la dinámica temporal disminuye. El pronóstico de series temporales, especialmente utilizando modelos como ARIMA, depende en gran medida de la cantidad y calidad de los datos disponibles.

Pronóstico de morosidad de cartera de consumo

El análisis de la morosidad de la cartera vencida incluyó la aplicación del modelo ARIMA para pronosticar el comportamiento futuro en cuanto a la morosidad de la cartera de consumo. Utilizando la función auto arima, se identificó el modelo óptimo para la serie, que resultó ser un modelo ARIMA con parámetros (1,0,0) y media distinta de 0. La Figura 2 muestra el pronóstico de esta variable para los meses próximos, basado en el modelo ARIMA ajustado.

Figura 2

Pronóstico de morosidad de la cartera de consumo




En los últimos meses de los datos históricos se observan fluctuaciones en la morosidad de la cartera de consumo. Esta tendencia continúa en el pronóstico, lo que indica que se espera que la morosidad para esta cartera tenga variaciones en los próximos meses. El intervalo de confianza ofrece un rango dentro del cual es probable que caigan los valores futuros de la morosidad. Por ejemplo, si el intervalo cubre un rango de 1 a 22 puntos en los próximos meses, esto sugiere que, aunque el modelo predice un valor específico (pronóstico puntual), hay una probabilidad considerable de que el valor real de la morosidad pueda ser mayor o menor dentro de ese rango. La tabla 3 presenta el pronóstico obtenido para la morosidad de la cartera de consumo, evidenciando un incremento para los meses siguientes.

Tabla 3*Intervalo de confianza en el pronóstico de morosidad de la cartera de consumo*

Fecha	Pronóstico Puntual (%)	Lo 95 (%)	Hi 95 (%)
Diciembre 2024	9.10	1.59	16.61
Enero 2025	10.57	1.57	19.60
Febrero 2025	11.56	1.56	21.17
Marzo 2025	12.21	2.34	22.08
Abril 2025	12.65	2.66	22.63
Mayo 2025	12.94	2.91	22.97

Pronóstico de la morosidad de la cartera de microcrédito

En el análisis de los datos históricos de la cartera de microcrédito se observó una un crecimiento en la morosidad a partir de 2023 hasta 2024. Se identificó que el modelo óptimo para los datos de la serie resultó ser un modelo ARIMA con parámetros (1,1,0). Esto implica que el modelo tiene un término autorregresivo de primer orden y se aplica una diferenciación. En la figura 3 se visualiza el pronóstico generado por el modelo ARIMA, donde se observa que la línea del pronóstico parece estabilizarse, sugiriendo que la morosidad de la cartera de microcrédito no aumentará o disminuirá significativamente en el corto plazo.

Figura 3*Pronóstico de morosidad de la cartera de microcrédito*


La morosidad de la cartera de microcrédito permanecerá relativamente estable en los próximos meses, pero existe una incertidumbre considerable que se refleja en el intervalo de confianza cada vez más amplio. El hecho de que la línea de pronóstico no muestra grandes oscilaciones sugiere que el modelo no espera fluctuaciones bruscas en la morosidad. En la tabla 4 se presenta el pronóstico puntual y el intervalo de confianza para los próximos meses.

Tabla 4*Intervalo de confianza en el pronóstico de morosidad de la cartera de microcrédito*

Fecha	Pronóstico Puntual (%)	Lo 95 (%)	Hi 95 (%)
Diciembre 2024	17.21	14.61	19.80
Enero 2025	17.27	14.17	20.38
Febrero 2025	17.25	13.55	20.95
Marzo 2025	17.26	13.09	21.42
Abril 2025	17.26	12.66	21.85
Mayo 2025	17.26	12.27	22.24

Pronóstico de morosidad de la cartera total

En los datos históricos de la variable morosidad de la cartera total, desde mediados de 2023 hasta 2024, la morosidad total muestra un incremento sostenido, con algunos picos. Esto sugiere que, aunque hubo intentos de reducir la mora o factores que lo permitieron temporalmente, las condiciones económicas o la situación de los deudores empeoraron en general, llevando a un aumento en la morosidad. Se identificó que modelo óptimo para los datos es un modelo ARIMA con parámetros (1, 1, 0) (0, 1, 0) [12], es decir, que el modelo tiene un término autorregresivo de primer orden y además requirió una diferenciación para eliminar una tendencia no estacionaria. La parte estacional (0,1,0) [12] indica que los errores de predicción de la serie en una temporada anterior (12 meses atrás, dado el subíndice [12]) afectan la predicción actual. En la figura 4 se observa la gráfica del pronóstico generado por el modelo ARIMA, en la cual se evidencia un incremento en la morosidad de la cartera total para los próximos meses.

Figura 4*Pronóstico de morosidad de la cartera total*

En comparación con las gráficas anteriores de la morosidad en la cartera de consumo y microcrédito, la gráfica de la morosidad total muestra un comportamiento que combina características de ambas. Hay un patrón ascendente similar al de la cartera de microcrédito, aunque con menor volatilidad que en la de consumo, pero con una tendencia general a aumentar a medida que pasa el tiempo. La tabla 5

muestra el pronóstico y el intervalo de confianza para los próximos meses, donde se evidencia el ascenso en la morosidad de la cartera total.

Tabla 5

Intervalo de confianza en el pronóstico de morosidad de la cartera total

Fecha	Pronóstico Puntual (%)	Lo 95 (%)	Hi 95 (%)
Diciembre 2024	16.70	13.73	19.66
Enero 2025	15.91	12.75	19.07
Febrero 2025	17.83	13.93	21.72
Marzo 2025	18.52	14.33	22.71
Abril 2025	18.94	14.30	23.58
Mayo 2025	19.77	14.83	24.72

4. Discusión

La predicción precisa de la morosidad en la cartera vencida es un desafío crítico para las instituciones financieras, ya que les permite anticipar y mitigar riesgos, optimizar la asignación de recursos y tomar decisiones informadas. En este estudio se aplicaron técnicas de análisis de series temporales para pronosticar el comportamiento de la cartera vencida, con el objetivo de proporcionar una herramienta valiosa para la gestión del riesgo de crédito.

Los resultados obtenidos en los análisis de este estudio evidencian que, en la cooperativa de ahorro y crédito de la ciudad de Riobamba intervenida, la morosidad de cartera total es alta, alcanzando el 16.57 % para el mes de noviembre de 2024. Según Toalombo-Villa & Cárdenas-Pérez (2023), las cooperativas de ahorro y crédito realizan constantemente esfuerzos sustanciales para mantener un nivel de morosidad no mayor al 5 % de la cartera total del crédito colocado. A partir de este dato, la diferencia de 11 puntos porcentuales por encima del índice de referencia deja en evidencia la alta morosidad existente en la cooperativa.

Esta tendencia se relaciona con el crecimiento de la morosidad en estas entidades en los últimos años. De acuerdo con Toapanta-Freire & Vásconez-Acuña (2024), en 2022 se reportó un índice de morosidad del 4.5 %, mientras que para 2023 este indicador alcanzó el 7.1 %, un incremento altamente significativo que evidencia el rápido crecimiento de la morosidad para este sector. Sin embargo, estos valores permanecen muy por debajo en comparación con los índices reportados por la cooperativa en estudio. La situación es aún más preocupante cuando se consideran las predicciones realizadas para un periodo de 6 meses futuros, en las que los datos de la cooperativa en cuanto a la morosidad de la cartera total continúan al alza, llegando a un valor puntual de 19.77 % en mayo de 2025.

En cuanto a la calificación de riesgos, la normativa de la SEPS (2023), órgano que regula el funcionamiento de cooperativas, bancos y cajas comunales, mutualistas y cajas de ahorro, establece que las cooperativas deben reportar regularmente su índice de morosidad y calificar la cartera de crédito y contingentes en función de la morosidad y al segmento de crédito al que pertenecen. Por lo tanto, se presenta una preocupación constante considerando que, en base a los datos, existe una morosidad incremental. En el rango de confianza, en el mejor de los casos, se estima que exista una morosidad de cartera total de 14.83 %, pero también se prevé que puede llegar a un punto de 24.72 %.

Dada la preocupante situación en la entidad bajo estudio resulta imperativo adoptar medidas estratégicas y tecnológicas para mitigar los riesgos asociados. Se recomienda innovar en el proceso de gestión de cobranzas mediante la implementación de un sistema automatizado de seguimiento y recuperación de deudas, que permita una interacción más eficiente y personalizada con los deudores. Además, se sugiere establecer un modelo de clasificación de clientes utilizando algoritmos de aprendizaje automático, lo que permitirá identificar de manera precisa aquellos clientes con mayor probabilidad de incumplir con sus obligaciones crediticias. Este enfoque no solo facilitará una asignación más efectiva de recursos en el proceso de cobranza, sino que también permitirá a la cooperativa diseñar estrategias de prevención enfocadas en los segmentos de clientes con mayor riesgo.

Paralelamente, es fundamental investigar y analizar los segmentos de clientes que presentan una menor probabilidad de incumplimiento, lo que puede servir de base para ajustar las políticas de crédito y desarrollar productos financieros más adecuados para estos grupos, minimizando así el riesgo general de la cartera. Finalmente, se debe considerar la implementación de políticas proactivas de educación financiera, con el fin de fomentar comportamientos de pago responsables y fortalecer la relación entre la cooperativa y sus socios.

5. Conclusiones

La investigación ha mostrado que las técnicas de pronóstico basadas en series temporales, incluyendo modelos ARIMA, de suavizamiento exponencial, y métodos avanzados de machine learning como LSTM, son herramientas robustas para analizar la morosidad de cartera vencida. Estos modelos permiten capturar patrones, tendencias y estacionalidades en los datos históricos, facilitando pronósticos precisos. En particular, los modelos ARIMA demostraron ser efectivos al proporcionar predicciones fiables que pueden ser utilizadas para una mejor gestión del riesgo crediticio. Estos modelos permiten a las instituciones financieras anticipar posibles incumplimientos y tomar medidas preventivas para mitigar los riesgos asociados.

La selección y preprocesamiento de los datos de cartera vencida de la cooperativa de ahorro y crédito se convierte en una etapa crítica en el proceso de pronóstico. Se recopilaron datos históricos, que van desde junio de 2021 hasta noviembre de 2024. Se realizó un proceso de análisis y transformación en los datos para asegurar la calidad y relevancia de la información utilizada. Este procedimiento garantizó que los datos estuvieran libres de inconsistencias y fueran aptos para el análisis predictivo. La metodología aplicada permitió obtener un conjunto de datos confiable y representativo, lo que facilitó la implementación efectiva de modelos de pronóstico y mejoró la precisión de las predicciones sobre la morosidad de cartera vencida.

El análisis de los datos de morosidad de cartera vencida permitió identificar patrones significativos que son esenciales para la gestión financiera de la cooperativa. Utilizando modelos ARIMA, se observó que la cartera de microcrédito muestra la tendencia más pronunciada al alza, sugiriendo una creciente dificultad en el cumplimiento de pagos por parte de los prestatarios en este segmento. En comparación, la cartera de consumo presenta fluctuaciones más marcadas, con picos y descensos significativos, indicando una mayor volatilidad en este tipo de créditos. Finalmente, la morosidad de la cartera total, que combina ambas dinámicas, revela un aumento gradual y sostenido, lo que subraya la necesidad de implementar estrategias de gestión de riesgo crediticio para mejorar la eficacia en la gestión del riesgo y asegurar la estabilidad financiera a largo plazo.

Ante esta situación, es crucial adoptar medidas estratégicas y tecnológicas para mitigar los riesgos. Se propone innovar el proceso de gestión de cobranzas mediante un sistema automatizado de seguimiento de deudas y un modelo de clasificación de clientes basado en algoritmos de aprendizaje automático. Esto permitirá identificar a los clientes con mayor riesgo de incumplimiento y ajustar las estrategias de cobranza y prevención. Además, es importante investigar a los clientes con menor riesgo para adaptar las políticas de crédito y productos financieros, y promover la educación financiera para fortalecer la relación con los socios y fomentar un comportamiento de pago responsable.

Referencias

- Abril, M. M. (2021). Modelos para el análisis de las series de tiempo. *RInCE*, 22(11), 1-6. <https://n9.cl/r5oeot>
- Cedeño-Jaramillo, J., & Zambrano-Montesdeoca, J. (2022). La recuperación de cartera vencida y su incidencia en la liquidez de la Cooperativa de Ahorro y Crédito Magisterio Manabita LTDA. 2021-2022. *Polo del Conocimiento*, 7(6), 1949-1973. <https://n9.cl/5lf041>
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models: An empirical study on performance estimation methods. *Machine Learning*, 109(11), 1997-2028. <https://doi.org/10.1007/s10994-020-05910-7>
- Contreras, L. A. C. (2020). Morosidad de la cartera de crédito al consumo y su incidencia en la rentabilidad y liquidez del Banco Mercantil, Banco Universal. *Gestión y desarrollo libre*, 5 (9). <https://doi.org/10.18041/2539-3669/gestionlibre.9.2020.8109>
- Deb, C., Zhang, F., Yang, J., Lee, S., & Shah, K. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902-924. <https://doi.org/10.1016/j.rser.2017.02.085>
- Deras, N. J., Ardón, J. A., & Domínguez, V. D. (2023). *Sistema de gestión de cartera que contribuya a contrarrestar el riesgo crediticio de la Asociación Cooperativa de Ahorro, Crédito y Consumo de Abogados de El Salvador de R. L.* [Tesis de grado, Universidad de El Salvador]. Repositorio institucional. <https://n9.cl/prqpaf>
- Garibaldi, L. A., Oddi, F. J., Azuaga, G. D., Behnisch, A. N., & Aristimuño, F. J. (2023). *Modelos estadísticos en lenguaje R*. Editorial UNRN. <https://n9.cl/b9ue6>
- Giorgi, F. M., Ceraolo, C., & Mercatelli, D. (2022). The R Language: An Engine for Bioinformatics and Data Science. *Life*, 12(5), 648. <https://doi.org/10.3390/life12050648>
- Kader, N., Yusof, U., Khalid, M., & Husain, N. (2023). A review of long short-term memory approach for time series analysis and forecasting. En *Proceedings of the 2nd International Conference on Emerging Technologies and Intelligent Systems* (pp. 12-21). Springer International Publishing. https://doi.org/10.1007/978-3-031-20429-6_2
- Kimata, J., Khan, M., Sharma, A., Rashid, M., & Tekabu, T. (26 al 30 de agosto de 2019). Forecasting of currency exchange rate using artificial neural network: a case study of Solomon Island dollar. En N. Abhaya & S. Alok (eds.), *PRICAI 2019: Trends in Artificial Intelligence* (pp. 729-733). Springer International Publishing. https://doi.org/10.1007/978-3-030-29894-4_58
- Kolambe, M., & Arora, S. (2024). Forecasting the future: a comprehensive review of time series prediction techniques. *Journal of Electrical Systems*, 20(2), 575-586. <https://doi.org/10.52783/jes.1478>

- Li, K., & Zhou, Y. (2024). Improved financial predicting method based on time series long short-term memory algorithm. *Mathematics*, 12(7). <https://doi.org/10.3390/math12071074>
- Lim, B., & Zohren, S. (2021). Time series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Miller, J., Aldosari, M., Saeed, F., Barna, N., Rana, S., Arpinar, I., & Liu, N. (2024). *A survey of deep learning and foundation models for time series forecasting*. Cornell University. <https://doi.org/10.48550/arXiv.2401.13912>
- Morales, J., Espinosa, P., & Rojas, M. (2022). Efecto de las variables macroeconómicas en los índices de morosidad de los bancos en México, durante el periodo COVID-19 versus el periodo previo. *Revista Academia & Negocios*, 8(1). <https://n9.cl/ik3oa>
- Mosso, M., & López-Herrera, F. (2019). Relación de equilibrio en la morosidad y el deterioro de la cartera de hipotecas bursatilizadas en México. *Revista de Investigación en Ciencias Contables y Administrativas*, 5(1), 3-31. <https://n9.cl/7mqsim>
- Murillo-Robles, M., & Palacios-Cedeño, N. (2022). Cartera vencida y la liquidez de la empresa Camposanto y Exequiales Jardines de la Paz Jipijapa, periodo 2019-2020. *Dominio de las Ciencias*, 8(2), 185-205. <https://n9.cl/gyed1>
- Noriega, J., Rivera, L., & Herrera, J. (2023). Machine learning for credit risk prediction: a systematic literature review. *Data*, 8(11), 169. <https://doi.org/10.3390/data8110169>
- Resolución 129-2015-F [Junta de la Política y Regulación Monetaria y Financiera]. Por la cual se establece la Norma para la gestión de riesgo de crédito en las cooperativas de ahorro y crédito. 23 de septiembre de 2015. <https://www.seps.gob.ec/wp-content/uploads/Resol129.pdf>
- Resolución Nro. SEPS-IGT-IGS-INSESF-INR-INGINT-2023-0225 [Superintendencia de Economía Popular y Solidaria]. Por la cual se establece la Norma de control para la gestión del riesgo de crédito. 22 de junio de 2023. <https://lc.cx/x-Y6eE>
- Ronquillo, M. (2020). *Gestión de mejora continua para proceso de captación y crédito, caso Cooperativa de Ahorro y Crédito San Antonio Montalvo* [Tesis de maestría, Universidad Tecnológica Empresarial de Guayaquil]. Repositorio institucional. <https://n9.cl/qfkmhx>
- Rubio, G. (2021). *Evaluación de gestión al proceso de recuperación de cartera vencida y su incidencia en la liquidez de la compañía Jardines Vida Eterna S. A.* [Tesis de grado, Universidad Laica Vicente Rocafuerte de Guayaquil]. Repositorio institucional. <https://n9.cl/go9nd>
- Ruiz, S., Leos, V., & Morales, J. (septiembre de 2018). *Métodos de clasificación supervisada en series temporales* [conferencia]. Conferencia Latinoamericana sobre Uso de R en Investigación+ Desarrollo (LatinR 2018)-JAIIO 47, Sociedad Argentina de Informática e Investigación Operativa, Argentina. <https://n9.cl/yzw7kb>
- Siarni-Namini, S., & Namin, A. (2018). *Forecasting economics and financial time series: ARIMA vs. LSTM*. Cornell University. <https://doi.org/10.48550/arXiv.1803.06386>
- Superintendencia de Economía Popular y Solidaria [SEPS]. (2024). *Estadísticas SFPS*. <https://n9.cl/eo4tv>
- Toalombo-Villa, J., & Cárdenas-Pérez, A. (2023). Gestión de recaudación de cartera vencida y su incidencia en los resultados financieros de la cooperativa de ahorro y crédito Ambato Ltda. Agencia Tena. *Revista Publicando*, 10(39), 17-29. <https://n9.cl/fvq5z>

- Toapanta-Freire, A., & Vásquez-Acuña, L. (2024). Riesgo crediticio y la estabilidad financiera de las Cooperativas de Ahorro y Crédito del Ecuador. *Gestio et Productio*, 6(1), 493-524. <https://doi.org/10.35381/gep.v6i1.112>
- Tudela-Mamani, J., Cahui-Cahui, E., Aliaga-Melo, G., Tudela-Mamani, J., Cahui-Cahui, E., & Aliaga-Melo, G. (2022). Impacto del COVID-19 en la demanda de turismo internacional del Perú. Una aplicación de la metodología Box-Jenkins. *Revista de Investigaciones Altoandinas*, 24(1), 27-36. <https://doi.org/10.18271/ria.2022.317>
- Vallejo, J., Torres, D., & Ochoa, J. (2021). Morosidad del sistema bancario producido por efectos de la pandemia. *ECA Sinergia*, 12(2), 17-24. https://doi.org/10.33936/eca_sinergia.v12i2.2959
- Yadav, M., Pal, N., & Yadav, D. (28 al 29 de enero de 2021). *Workload prediction over cloud server using time series data*. 2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence), IEEE, Noida, India. <https://doi.org/10.1109/Confluence51648.2021.9377032>
- Zhou, Q., Han, R., Li, T., & Xia, B. (2019). Joint prediction of time series data in inventory management. *Knowledge and Information Systems*, 61(2), 905-929. <https://doi.org/10.1007/s10115-018-1302-y>

Transparencia

Conflicto de interés

Los autores declaran que no existen conflictos de interés de naturaleza alguna.

Fuente de financiamiento

Los autores financiaron completamente la investigación.

Contribución de autoría

Cristina Monserrateh Ibarra Gallo: Conceptualización, metodología, software, validación, análisis formal, investigación, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, administración del proyecto, recursos, supervisión.

Marco Antonio Daqui Janeta: Conceptualización, metodología, software, validación, análisis formal, investigación, gestión de datos, visualización, redacción - preparación del borrador original, redacción - revisión y edición, financiamiento, recursos.

Los autores contribuyeron activamente en el análisis de los resultados, revisión y aprobación del manuscrito final.