



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Prototipo de un sistema de apoyo para toma de decisiones en la gestión de reclamos en Empresas de Servicios Públicos

María Cristina Castaño Pabón

Universidad Nacional de Colombia
Facultad de Minas, Área Curricular de Sistemas e Informática
Medellín, Colombia

2023

Prototipo de un Sistema de Apoyo para Toma de Decisiones en la Gestión de Reclamos en Empresas de Servicios Públicos

María Cristina Castaño Pabón

Trabajo final presentado como requisito parcial para optar al título de:
Magister en Ingeniería - Analítica

Director:

Juan David Velásquez Henao, MSc, PhD

Nodo Profundización

Universidad Nacional de Colombia
Facultad de Minas, Área Curricular Ingeniería de Sistemas e Informática
Medellín, Colombia

2023

*A mi mamá Angela, mi papá Guillermo y mis
hermanos Juliana y Juan Andrés.*

Declaración de obra original

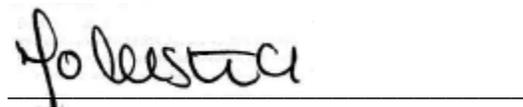
Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.



María Cristina Castaño Pabón

Fecha 13/07/2023

Agradecimientos

Quiero agradecer a mis padres Angela y Guillermo, quienes siempre me han motivado a seguir mis sueños y me han brindado su amor y apoyo incondicional a lo largo de toda mi vida. Su dedicación y sacrificio han sido una fuente constante de inspiración para mí. Sin su amor y confianza en mis capacidades, este logro no hubiera sido posible.

A mis hermanos Juliana y Juan Andrés, gracias por sus palabras de ánimo en esos momentos en que quise renunciar, por acompañarme en tantas noches de desvelo y por siempre confiar en mí.

Un agradecimiento especial al profesor Juan David Velásquez, director de este trabajo. Su guía experta, paciencia y dedicación fueron fundamentales en la realización de este trabajo. Agradezco por compartir su conocimiento conmigo, por los valiosos consejos y porque siempre tuvimos una razón para reírnos.

También quiero expresar mi agradecimiento a Carlos Arley Gómez, Jefe de la Unidad Soporte Clientes de EPM, la dependencia en la que desempeñé mi labor. Su disposición para proporcionar los datos necesarios resultó fundamental en la realización de este trabajo de investigación.

¡Gracias!

Resumen

Prototipo de un sistema de apoyo para toma de decisiones en la gestión de reclamos en Empresas de Servicios Públicos

Las empresas de servicios públicos deben responder a tiempo las PQR (Peticiónes, Quejas y Reclamos) de sus usuarios. En el caso específico de EPM, el número de PQR recibidas mensualmente ha experimentado fuertes variaciones, especialmente durante la pandemia del COVID-19. Esto ha ocasionado retrasos en los tiempos de respuesta debido a la falta de pronóstico en la cantidad de PQR que se recibirán en los próximos meses, lo que impide una óptima asignación de recursos humanos. En este trabajo de investigación de la maestría, se exploraron diferentes tipos de modelos para pronosticar tanto la serie agregada de reclamos diarios recibidos, como las series individuales asociadas a cada ciclo de facturación. Como resultado, se encontró que el modelo ARIMA brinda el pronóstico más preciso para la serie agregada de reclamos. Este modelo se utiliza en un sistema de simulación que permite estimar los KPI (Indicadores Clave de Desempeño) relevantes del proceso, con el propósito de brindar información para la toma de decisiones.

Palabras clave: Pronostico, series de tiempo, Empresas de Servicios Públicos, PQR, sistema de simulación, ARIMA, tiempo de respuesta.

Abstract

Prototype of a decision support system for claim management in Public Utility Companies.

Public utility companies must respond to PQR (Petitions, Complaints, and Claims) from their users in a timely manner. In the specific case of EPM, the number of PQRs received monthly has experienced significant variations, especially during the COVID-19 pandemic. This has resulted in delays in response times due to the lack of forecasting the quantity of PQR that will be received in the coming months, hindering optimal allocation of human resources.

In this master's research work, different types of models were explored to forecast both the aggregated series of daily received claims and the individual series associated with each billing cycle. As a result, it was found that the ARIMA model provides the most accurate forecast for the aggregated series of claims. This model is used in a simulation system that allows estimating the relevant Key Performance Indicators (KPIs) of the process, aiming to provide information for decision-making.

Keywords: Forecast, time series, Public utility companies, PQR, simulation system, ARIMA response times.

Contenido

	Pág.
1. Introducción	15
1.1 Definición del problema de negocio.....	15
1.2 Definición del problema de analítica.....	17
1.3 Estado del arte.....	18
1.4 Definición problema de trabajo.....	19
1.5 Hipótesis.....	20
1.6 Objetivos.....	20
1.6.1 Objetivo general.....	20
1.6.2 Objetivos específicos.....	20
2. Análisis exploratorio.....	21
2.1 Información utilizada.....	21
2.2 Serie agregada de reclamos.....	21
2.3 Series de reclamos por ciclos.....	22
2.4 Estacionariedad.....	24
2.5 Estacionalidad.....	24
2.6 Autocorrelación y Autocorrelación Parcial.....	25
2.7 Distribución temporal de la serie de tiempo.....	27
2.7.1 Distribución mensual.....	27
2.7.2 Distribución diaria.....	28
2.7.3 Distribución semanal.....	28
3. Modelos Autorregresivo y ARIMA.....	31
3.1 Consideraciones generales.....	31
3.2 Criterios de evaluación.....	32
3.3 Modelo Autorregresivo recursivo.....	34
3.3.1 Optimización de los parámetros.....	35
3.4 Modelo ARIMA.....	35
3.4.1 Optimización de los parámetros.....	36
3.5 Comparación de modelos.....	36
4. Modelo con Redes Neuronales.....	39
4.1 Red Neuronal.....	39
4.2 Modelo 1: serie sin transformar.....	40
4.3 Modelo 2: serie transformada.....	40
4.4 Comparación de modelos.....	41
5. Elección del modelo y Prototipo de simulación.....	43
5.1 Elección del mejor modelo de pronostico.....	43

5.2	Prototipo de simulación.....	44
5.3	Simulación del pronóstico y comparación con la serie real	46
6.	Conclusiones y recomendaciones	51
6.1	Respuesta a la hipótesis.....	51
6.2	Cumplimiento de objetivos	51
6.2.1	Objetivo específico 1	52
6.2.2	Objetivo específico 2 y 3	52
6.3	Recomendaciones y trabajo futuro.....	53
7.	Bibliografía	55

Lista de figuras

	Pág.
Figura 1-1 <i>Histograma tiempo promedio de atención</i>	17
Figura 2-1 <i>Serie agregada de reclamos</i>	22
Figura 2-2 <i>Ciclos de facturación de la serie de tiempo</i>	23
Figura 2-3 <i>Descomposición aditiva de la serie</i>	25
Figura 2-4 <i>Autocorrelación y Autocorrelación Parcial</i>	26
Figura 2-5 <i>Distribución mensual de la serie de tiempo</i>	27
Figura 2-6 <i>Distribución diaria de la serie de tiempo</i>	28
Figura 2-7 <i>Distribución semanal de la serie de tiempo</i>	29
Figura 3-1 <i>Conjunto de entrenamiento, validación y prueba</i>	32
Figura 3-2 <i>Comparación modelos vs serie agregada</i>	37
Figura 4-1 <i>Comparación modelos vs serie agregada</i>	42
Figura 5-1 <i>Comparación de la serie agregada y el pronóstico con el modelo ARIMA</i>	44
Figura 5-2 <i>Flujo de trabajo – Tomado de (Velasquéz Henao, 2022)</i>	45
Figura 5-3 <i>Comparación de los reclamos “en progreso” de la serie agregada y el pronóstico</i>	48
Figura 5-4 <i>Comparación de los tiempos de respuesta de la serie de agregada y el pronóstico</i>	49
Figura 5-5 <i>Comparación de la cantidad de transacciones atendidas vs tiempo, para la serie agregada y el pronóstico</i>	50

Lista de tablas

	Pág.
Tabla 3-1 <i>Comparación de errores de los modelos AR y ARIMA</i>	37
Tabla 4-1 <i>Comparación de errores de los modelos de la serie transformada y sin transformar</i>	41
Tabla 5-1 <i>Comparación de errores de los modelos desarrollados</i>	44

1. Introducción

En la actualidad, las empresas de servicios públicos domiciliarios se encuentran inmersas en un entorno donde se generan y recopilan una gran cantidad de datos. Ante este panorama, se vuelve fundamental aprovechar al máximo esta información valiosa mediante el uso de herramientas de analítica de datos. De esta manera, las empresas pueden identificar nuevas oportunidades, anticipar escenarios y tomar decisiones más acertadas, lo que se traduce en procesos operativos más eficientes y un impacto positivo en la experiencia del cliente, al optimizar la gestión de estos reclamos, mejorar los tiempos de respuesta y brindar una atención más eficiente y satisfactoria a los clientes.

En este contexto, el presente trabajo se enfoca en un objetivo específico: desarrollar un modelo que permita pronosticar la demanda diaria de reclamos que ingresan por el canal escrito. Para lograrlo, se dividió el trabajo en varios capítulos: en Capítulo 1 se abordan las definiciones de los problemas tanto desde el punto de vista del negocio como de la analítica, se realiza una revisión de las metodologías disponibles y se analiza el estado del arte en el campo de la predicción de demanda en el sector de servicios públicos domiciliarios. En el Capítulo 2 se realizó el análisis exploratorio de la serie de tiempo, en el Capítulo 3 se plantean los modelos AR y ARIMA para pronosticar la demanda, en el Capítulo 4 se plantea el modelo de predicción usando Redes Neuronales y en el Capítulo 6 se responden las preguntas de investigación y se presentan las conclusiones.

1.1 Definición del problema de negocio

Las Empresas de Servicios Públicos Domiciliarios se enfrentan al desafío de optimizar y mejorar sus procesos de atención al cliente, ya que es común que sean criticadas debido a los largos tiempos de respuestas a sus trámites. En los últimos años, las empresas del

sector público, como la DIAN, la Contraloría y la Procuraduría, han adoptado modelos de analítica avanzada apoyados en el uso de inteligencia artificial, lo que les ha permitido ser más eficientes en el desarrollo de sus respectivos procesos de atención al cliente.

Dentro de las Peticiones, Quejas y Reclamos (PQR) recibidas en el área de atención al cliente, se encuentran los reclamos; estas son solicitudes realizadas para que se revise la facturación de los servicios públicos de acuerdo con el contrato de condiciones uniformes, la Ley 142 de 1994 y el Código de Procedimiento Administrativo y de lo Contencioso Administrativo. Uno de los aspectos fundamentales para resolver este problema es contar con el número adecuado de personal que permita atender estas transacciones, cumpliendo con los tiempos de respuesta establecidos por la normativa.

Un ejemplo de esta situación se presenta en las Empresas Públicas de Medellín (EPM). En dicha organización, existe un área encargada de atender todas las comunicaciones que ingresan por el canal escrito (web y cartas físicas radicadas en las diferentes oficinas). Durante el año 2020, esta área experimentó un aumento en sus transacciones debido a la pandemia, como consecuencia del cierre de oficinas y las restricciones a la movilidad en el país. Esto causó una sobrecarga en los equipos de trabajo, lo que llevó a un incremento en el pago de horas extras, fatiga física y mental del personal, y la posibilidad de incurrir en un silencio administrativo positivo (SAP) al no cumplir con el tiempo establecido de respuesta o no responder adecuadamente a la solicitud del cliente.

La razón subyacente del problema en la atención de la demanda es que la cantidad de reclamos varía a lo largo del mes, lo que dificulta la optimización del recurso humano encargado de la atención. Por lo tanto, es necesario contar con mecanismos que permitan establecer cómo será la demanda en el futuro y, de esta forma, ajustar la cantidad de personal necesario para atender los requerimientos.

Para diseñar un prototipo que cumpla con estos requisitos, se calcularon los KPI (Key Performance Indicators) relevantes del proceso, como el tiempo promedio de respuesta y la cantidad de casos en estado “*pendiente de atención*”. Tener una estimación de la demanda permitiría reprogramar la asignación de personal y podría mejorar estos indicadores clave de desempeño (KPI).

En la Figura 1-1, se muestra la distribución del tiempo promedio de atención de un reclamo desde el 2016 hasta el 2021. Se puede observar que la mayoría de los reclamos se atienden en un periodo de 8 y 10 días.

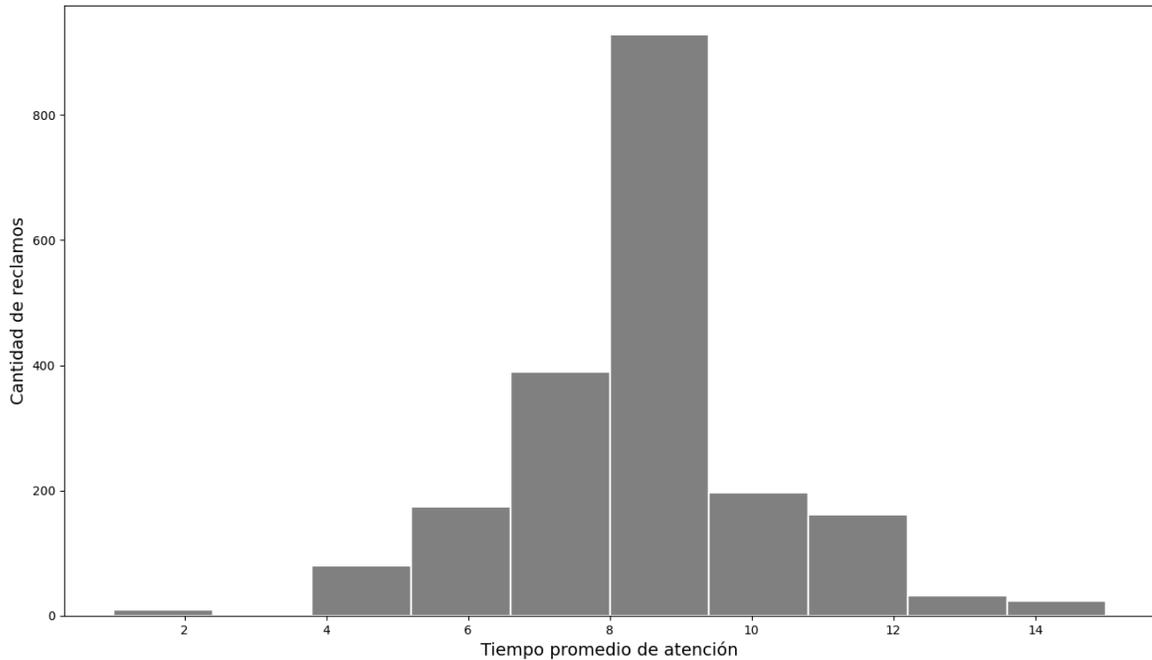


Figura 1-1 *Histograma tiempo promedio de atención*

1.2 Definición del problema de analítica

En términos analíticos, el objetivo principal es desarrollar un modelo que permita pronosticar la cantidad de reclamos que se esperan recibir en cada día del mes, con el propósito de optimizar el recurso humano en el área encargada de su atención. Actualmente, no se cuenta con una base sólida para llevar a cabo este proceso, y el personal se distribuye en función del comportamiento de los datos históricos. Esto implica que las decisiones sean reactivas y no proactivas.

Para abordar esta problemática, se propone el uso de modelos analíticos que permitan pronosticar la cantidad de reclamos que ingresarán a través del canal escrito, considerando el ciclo mensual de facturación. La implementación de este modelo proporcionaría al área

encargada la cantidad adecuada de personal para atender las transacciones, lo que resultaría en una mejora significativa en los tiempos de respuesta al cliente.

Estos cambios se traducirían en una reducción de costos operativos, una mayor confiabilidad en la prestación del servicio y un mayor compromiso con el cliente. Al anticiparse a la demanda de reclamos, la empresa podrá asignar eficientemente los recursos humanos necesarios, evitando tanto la subutilización como la sobrecarga de personal.

1.3 Estado del arte

Se realizó una revisión de las investigaciones relacionadas con el pronóstico de la demanda en el servicio al cliente y se encontró documentación centrada en el desarrollo y la aplicación de diversas metodologías capaces de proporcionar resultados confiables.

En el artículo "*Conditional Gaussian Mixture Model for Warranty Claims Forecasting: Reliability Engineering and System Safety*" (Chehade, Savargaonkar, & Krivtsov, 2022), los autores se enfrentaron a la dificultad de pronosticar la demanda de garantías para productos nuevos. Para abordar esta cuestión, desarrollaron un modelo de mezcla gaussiana condicional (CGMM) que utiliza datos históricos de productos similares para establecer una tendencia y luego aplicaron teorías bayesianas para estimar la distribución posterior.

Siguiendo la misma línea, en el trabajo de (Shaomin & Akbarov, 2012), se construyó un algoritmo de modelado en dos fases para pronosticar reclamaciones. En la primera fase, se estimaron los límites superior e inferior en el historial de reclamaciones, mientras que en la segunda fase se utilizó un proceso de Poisson no homogéneo (NHPP) para el pronóstico de las reclamaciones.

Otra investigación que aplicó un enfoque estadístico fue el artículo "*Using a Data-Driven Neural Network Approach to Forecast Building Occupant Complaints*" (Assaf & Srour,

2021). En este estudio, se abordó el pronóstico de la cantidad de quejas presentadas por los habitantes de un edificio como parte de una estrategia de mantenimiento predictivo planificado por la administración. Los autores desarrollaron un modelo de perceptrón multicapa (MLP) que mostró un rendimiento superior al modelo ARIMA.

El pronóstico de reclamaciones también se ha abordado en áreas como la salud. En el artículo "*A Big Data Analytics Framework for Forecasting Rare Customer Complaints: A Use Case of Predicting MA Members*" (Donghui, 2017), el autor diseñó un árbol de decisión único basado en el algoritmo Large Ensemble with Over-Sampling (LEOS), el cual imita el bosque aleatorio, pero con un sobre muestreo.

1.4 Definición problema de trabajo

El objetivo es pronosticar la serie de tiempo de reclamos diarios con un horizonte de 15 días, con el propósito de distribuir adecuadamente el personal necesario para atender la demanda. Además, se busca simular el comportamiento de esta demanda y, en caso necesario, realizar ajustes en la estructura del equipo para evitar el aumento del tiempo promedio de respuesta y la carga acumulada.

Para lograr esto, se utilizará la información diaria proporcionada por EPM abarcando el período comprendido entre el 1 de enero de 2016 y el 31 de diciembre de 2021. Estos datos están organizados en 21 ciclos de facturación, los cuales han sido definidos por la empresa.

En este tipo de casos, existen dos enfoques posibles: pronosticar la serie agregada de reclamos o pronosticar la serie correspondiente a cada ciclo de facturación. Ambas opciones serán consideradas y evaluadas en el desarrollo de este trabajo.

1.5 Hipótesis

La hipótesis planteada es la siguiente:

¿Es posible desarrollar un modelo de pronóstico para determinar la cantidad futura de reclamos que ingresan diariamente por el canal escrito en las empresas de servicios públicos domiciliarios, con el fin de tomar decisiones?

1.6 Objetivos

1.6.1 Objetivo general

Desarrollar modelos para pronosticar la cantidad de reclamos diarios que ingresan al canal escrito, y que permitan comparar diferentes aproximaciones al problema.

1.6.2 Objetivos específicos

Los objetivos específicos de este trabajo final son los siguientes:

1. Realizar el análisis exploratorio de los datos con el fin de determinar que consideraciones deberían tenerse en cuenta para construir modelos que permitan pronosticar la cantidad de reclamos que ingresan por el canal escrito.
2. Desarrollar un modelo tradicional de series de tiempo que permita el pronóstico de la serie agregada de reclamos diarios.
3. Desarrollar un modelo de pronóstico que combine los pronósticos diarios de cada ciclo de facturación mensual.

2. Análisis exploratorio

En este capítulo se desarrolla el Objetivo Especifico 1 “Realizar el análisis exploratorio de los datos con el fin de determinar que consideraciones deberían tenerse en cuenta para construir modelos que permitan pronosticar la cantidad de reclamos que ingresan por el canal escrito”. Para ello, se describirá la base de datos utilizada, se analizará su estacionariedad, se llevará a cabo la descomposición de la serie y se realizará un análisis de correlación para determinar los retardos sugeridos para los modelos de pronóstico.

2.1 Información utilizada

La información utilizada corresponde a un conjunto de 1.469 registros que contiene la cantidad de reclamos recibidos en el canal escrito, en el periodo comprendido entre el 1 de enero de 2016 y el 31 de diciembre de 2021, clasificados por ciclo de facturación. Un ciclo de facturación se refiere a las fechas que componen el periodo de consumo de los clientes y sobre el cual se aplica la tarifa de los servicios públicos. En total, se cuentan con 21 ciclos de facturación para el año contable.

2.2 Serie agregada de reclamos

La Figura 2-1 muestra el comportamiento diario de los reclamos. Se observa un patrón estable desde el 2016 hasta enero del 2020 con un ligero crecimiento en estos años. Sin embargo, se registra un valor atípico en junio de 2017 debido a una reclamación múltiple realizada por un conjunto residencial compuesto por 318 apartamentos.

En marzo de 2020, se dio inicio al periodo de pandemia y cuarentena obligatoria. Como parte de las medidas restrictivas implementadas, se estableció el cierre de las oficinas de atención al cliente para evitar aglomeraciones de personas en un mismo lugar. Esta situación motivó a los usuarios a recurrir a canales alternativos de atención, especialmente el canal escrito, y en particular la página web. Como resultado, se produjo un aumento significativo en las transacciones, alcanzando su punto máximo en junio, para luego comenzar a disminuir a medida que las oficinas retornaban a su operación normal. Esta transición se completó en septiembre de 2020.

A partir del año 2021, la cantidad de reclamos se estabilizó, aunque se mantuvo por encima de los niveles históricos anteriores a la pandemia

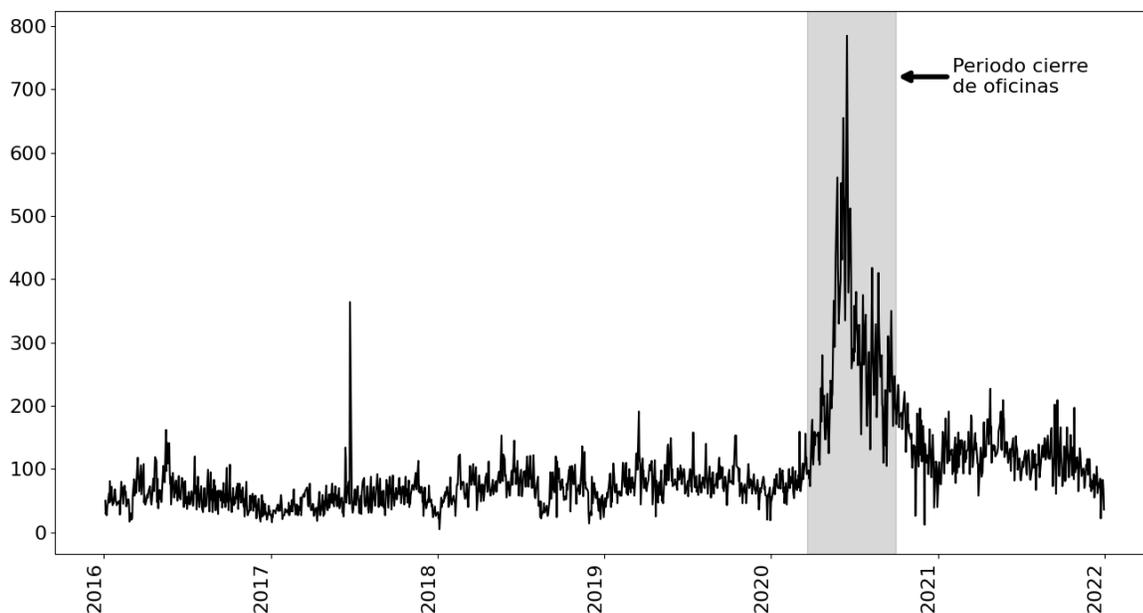


Figura 2-1 Serie agregada de reclamos

2.3 Series de reclamos por ciclos

La Figura 2-2 presenta el comportamiento de los 21 ciclos de facturación del año contable, que forman la serie de tiempo previamente descrita. Se puede observar que todos los

ciclos siguen un patrón consistente y similar a medida que transcurre el tiempo. Además, se destaca un incremento significativo en la cantidad de reclamos durante el periodo de la pandemia. Esta tendencia ascendente en el número de reclamos refleja el impacto de la situación de emergencia sanitaria en la demanda de servicios y en las interacciones de los clientes con la empresa.

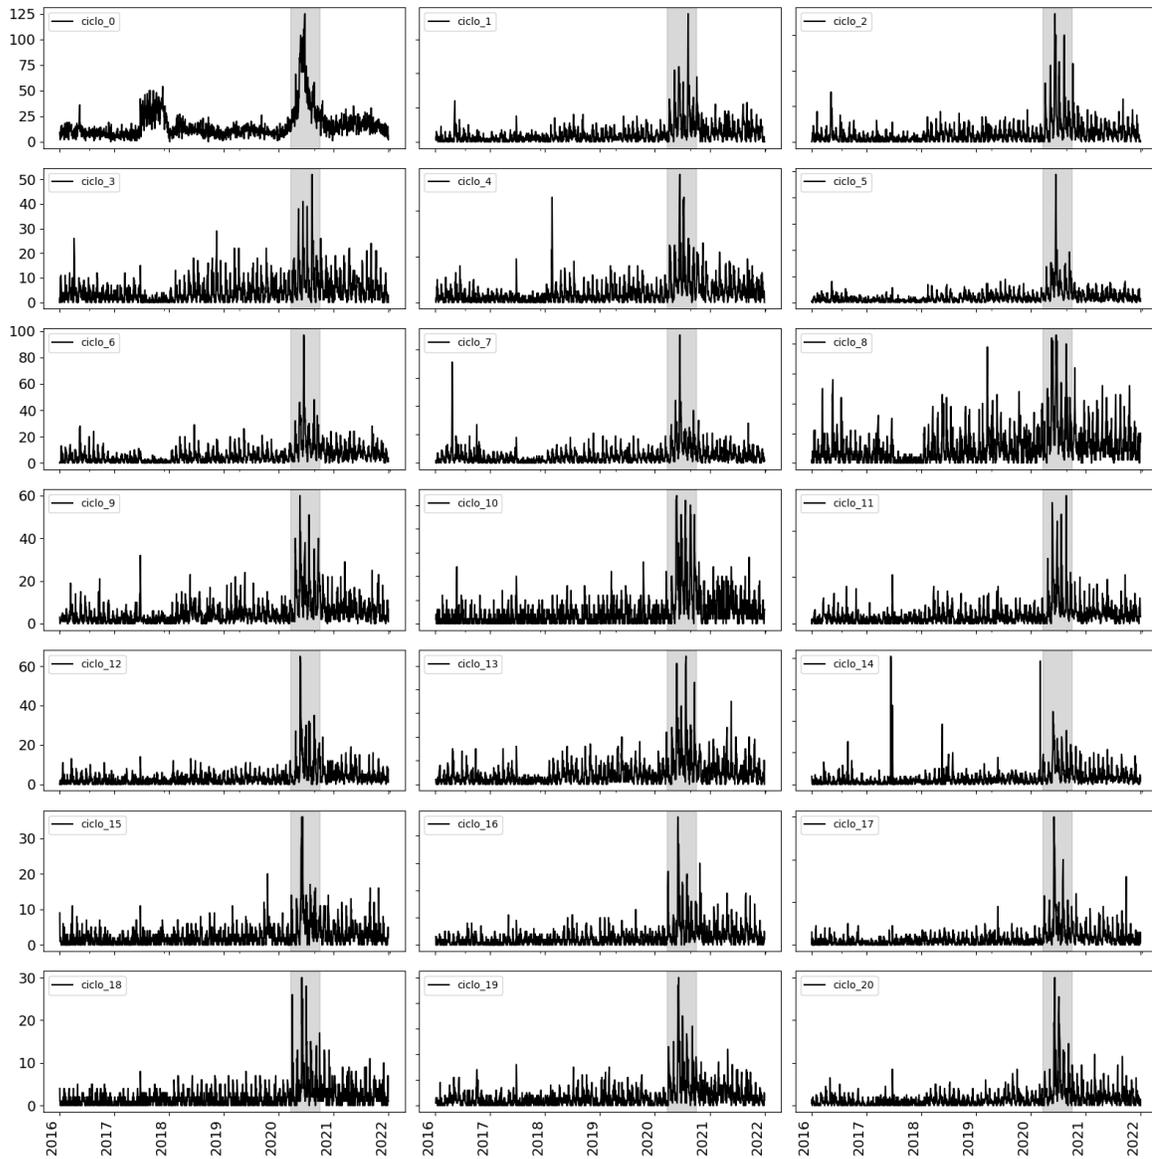


Figura 2-2 Ciclos de facturación de la serie de tiempo

2.4 Estacionariedad

Se realizó la prueba de *Dickey-Fuller* Aumentada (ADF), para determinar la estacionariedad de la serie, estableciendo como hipótesis nula que la serie es NO Estacionaria.

$$\begin{aligned} H_0 & : \rho = 0, \text{ la serie NO es estacionaria} \\ H_1 & : \rho < 0, \text{ la serie es estacionaria} \end{aligned}$$

De acuerdo con los resultados presentados, el *valor p* es menor que *0.05*, por lo tanto, se rechaza la hipótesis nula y se concluye que la serie de tiempo posee estacionariedad. Esto implica que las propiedades de la serie no varían a lo largo del tiempo.

2.5 Estacionalidad

Usando el modelo aditivo, se realizó la descomposición de la serie de tiempo para encontrar sus respectivas componentes: la tendencia, la estacionalidad y los residuos. El resultado de esta descomposición se puede observar en la Figura 2-3. La serie presenta una tendencia positiva hasta junio de 2020, momento en el que alcanza su punto máximo y comienza a descender. En cuanto a la estacionalidad, se puede determinar que existe una repetición de patrones mensuales. Por último, los residuos muestran un comportamiento atípico en la serie de tiempo durante el año 2020, correspondiente a la pandemia, y no presentan patrones repetitivos en el tiempo. Dado que esta componente es muy pequeña, puede obviarse en el análisis.

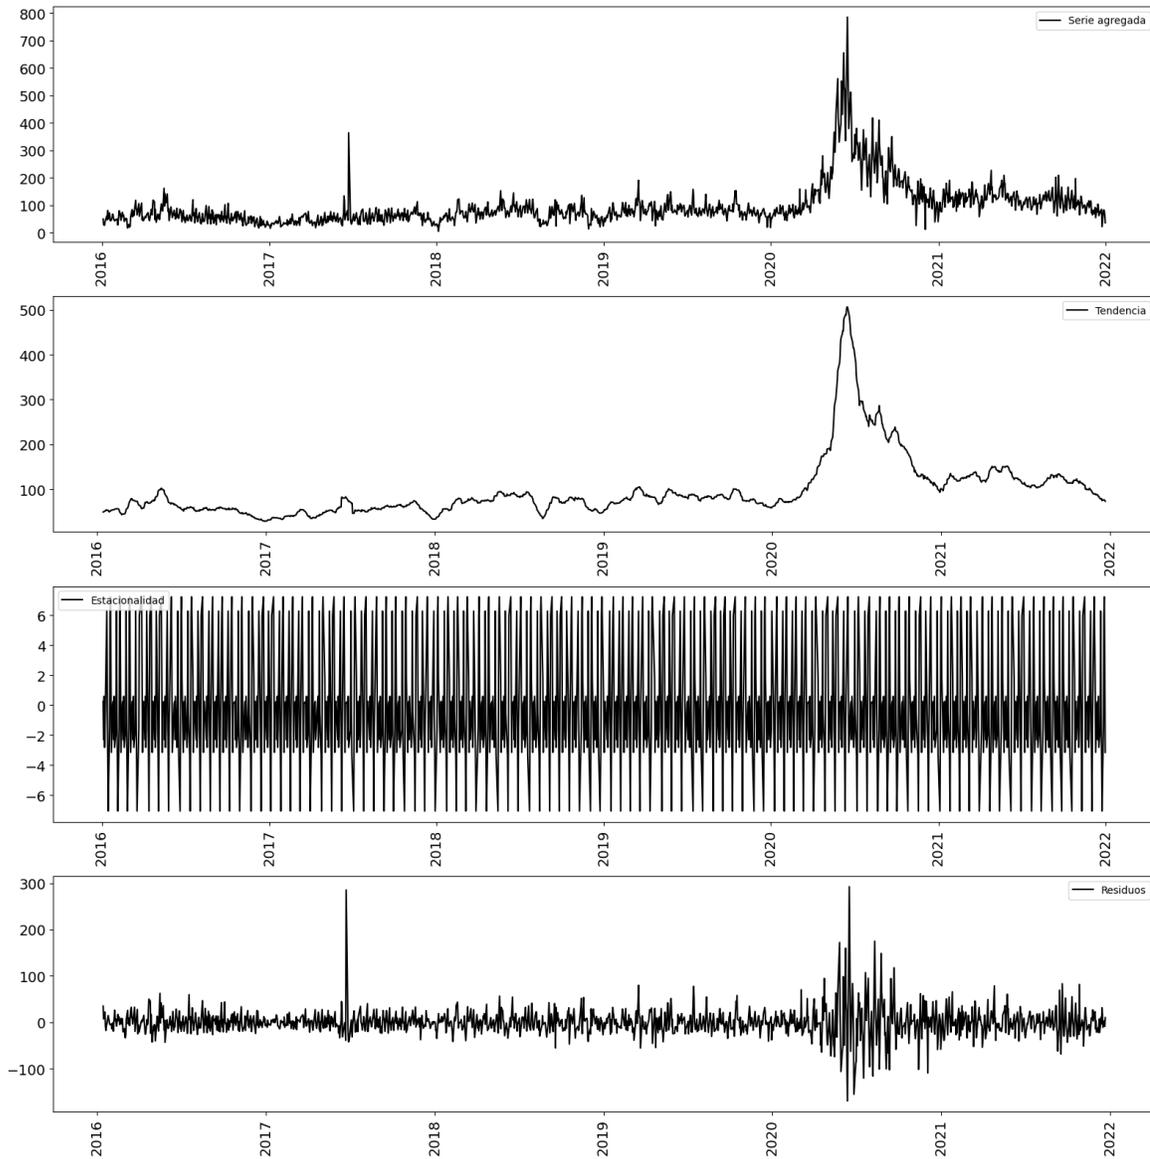


Figura 2-3 Descomposición aditiva de la serie

2.6 Autocorrelación y Autocorrelación Parcial

El análisis de la autocorrelación y la autocorrelación parcial de la serie de tiempo revela información importante sobre la estructura y el comportamiento de los datos.

La autocorrelación representa la asociación existente entre los valores actuales de la serie y los valores pasados, lo que permite identificar patrones repetitivos en los datos. En este

caso, en la Figura 2-4, se observa que la serie de tiempo exhibe un comportamiento cíclico con un período de 5 días, lo que indica una regularidad semanal en los datos. Esto sugiere que ciertos eventos o factores podrían influir en los valores de la serie cada semana.

Por otro lado, la autocorrelación parcial proporciona información sobre la asociación entre los valores actuales y los valores pasados, teniendo en cuenta las correlaciones intermedias. En la Figura 2-4, se observa que la autocorrelación parcial también muestra picos significativos con un período de 5 días, que se encuentran por encima del nivel de significancia. Esto indica que incluso después de tener en cuenta las correlaciones anteriores, todavía existe una relación importante entre los valores separados por 5 días en la serie de tiempo.

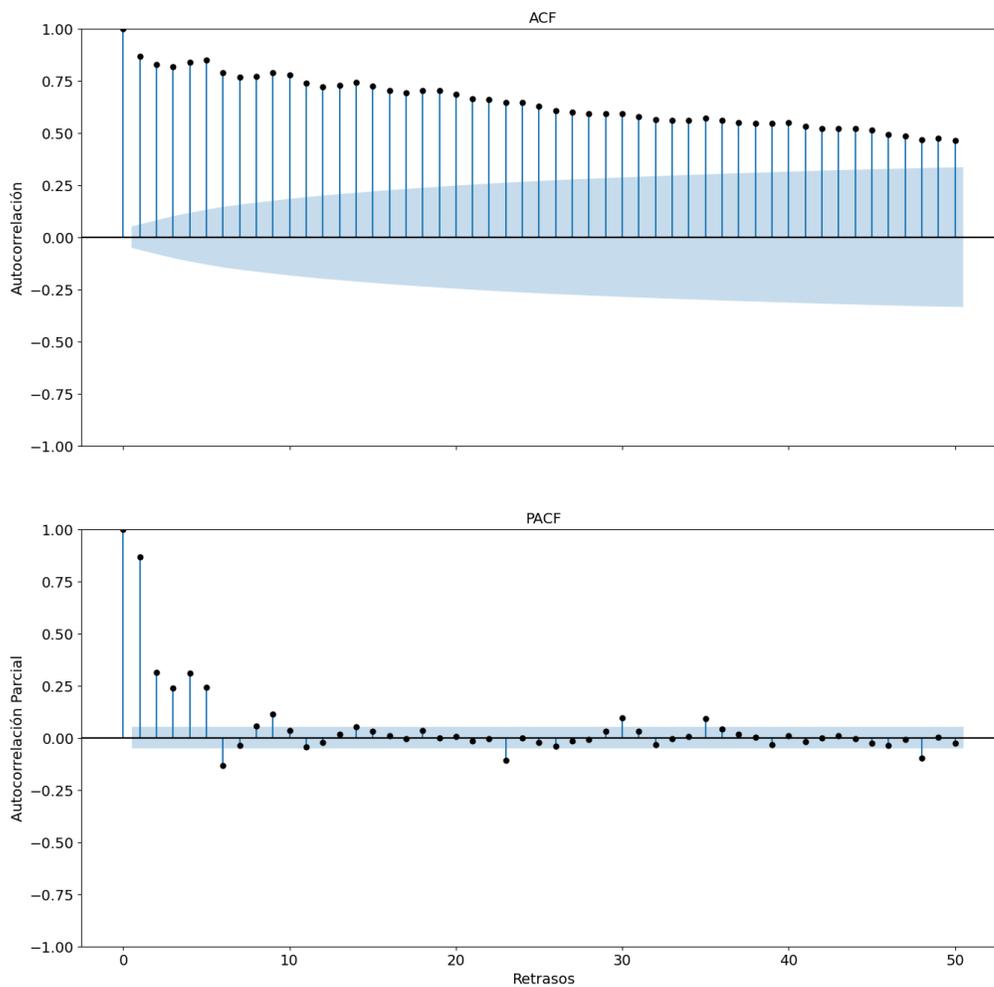


Figura 2-4 Autocorrelación y Autocorrelación Parcial

2.7 Distribución temporal de la serie de tiempo

Con el fin de detectar patrones o tendencias en los datos, se construyeron gráficas de diagrama de caja (*boxplot*), en periodos de tiempo específicos: anual, mensual y diario. Estas representaciones gráficas permitieron identificar patrones, tendencias y analizar el comportamiento de la serie de tiempo de manera más detallada.

2.7.1 Distribución mensual

La Figura 2-5 muestra la distribución de los datos mensualmente; se observan dos aumentos en las transacciones: el primero durante los meses de marzo, abril y mayo y el segundo en septiembre y octubre; estos movimientos pueden ser atribuidos a los reclamos relacionados con la facturación durante el periodo de vacaciones escolares de principio de año, semana santa y semana de receso; otra causa de estos incrementos son los reclamos atendidos por exenciones de la contribución, realizadas por los clientes cada 6 meses.

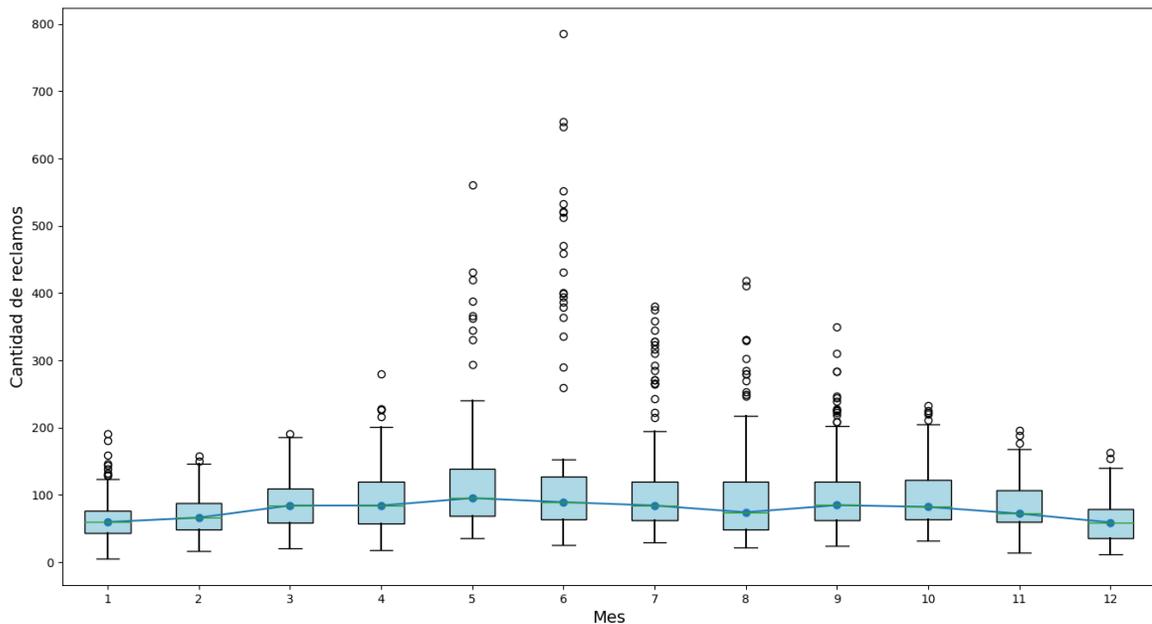


Figura 2-5 Distribución mensual de la serie de tiempo

El tercer cuartil de mayo y junio muestran un crecimiento variable y también durante estos meses se observan datos atípicos que son atribuibles a la situación generada por la pandemia.

2.7.2 Distribución diaria

La Figura 2-6 muestra que la cantidad de reclamos se incrementa a partir del día 9 y disminuye desde el día 27 del mes, esto corresponde a los días de pago factura o el plazo para realizar un abono parcial.

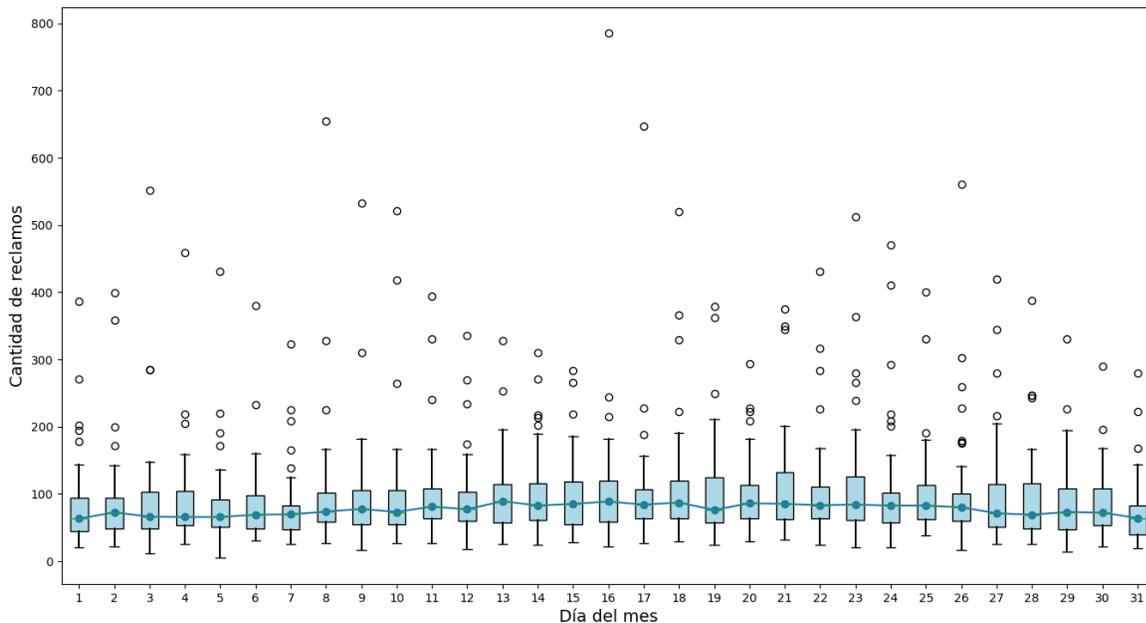


Figura 2-6 Distribución diaria de la serie de tiempo

2.7.3 Distribución semanal

La Figura 2-7 ilustra el análisis de la cantidad de reclamos recibidos en función del día de la semana y se observa que los lunes y los martes muestran el mayor número de reclamaciones registradas.

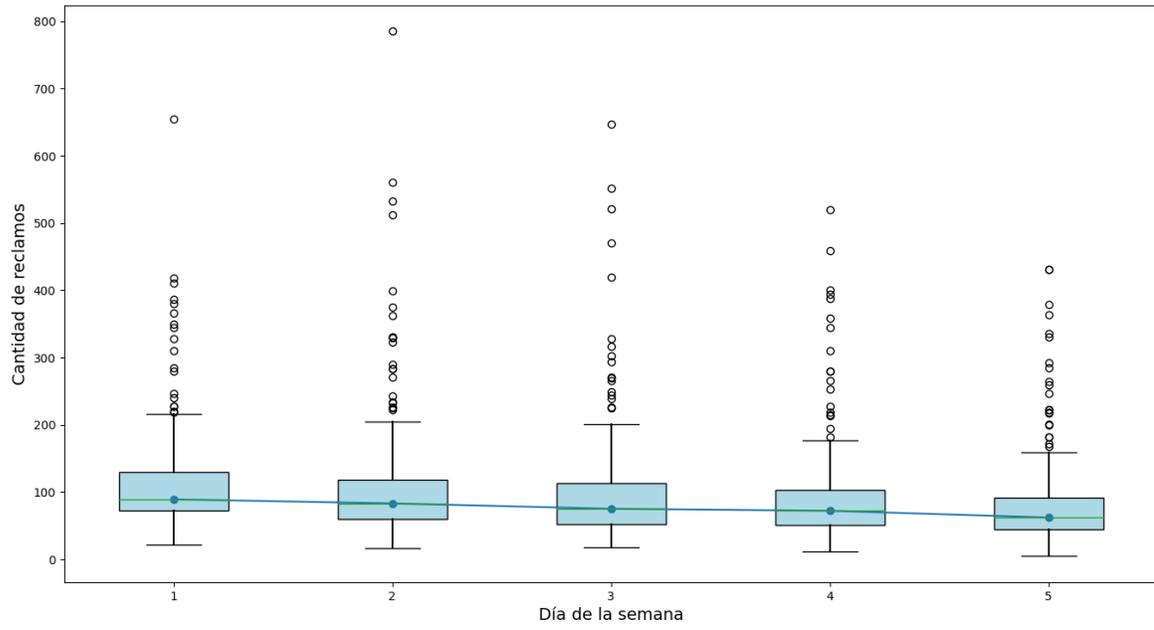


Figura 2-7 Distribución semanal de la serie de tiempo

3. Modelos Autorregresivo y ARIMA

En este Capítulo se desarrollan dos Objetivos Específicos: el Objetivo Especifico 2 que consiste en “Desarrollar un modelo tradicional de series de tiempo que permita el pronóstico de la serie agregada de reclamos diarios”; y el Objetivo Especifico 3, que busca “Desarrollar un modelo de pronóstico que combine los pronósticos diarios de cada ciclo de facturación mensual”. Para esto lograr esto, se utilizaron dos modelos de pronóstico: el Autorregresivo recursivo y ARIMA. Se describirá la metodología usada, el cálculo de las medidas de calidad y las gráficas comparativas de los resultados para obtenidos para elegir el pronóstico más preciso.

3.1 Consideraciones generales

En la Figura 3-1 se puede observar la división de la serie de tiempo en tres conjuntos de datos:

- Conjunto de entrenamiento: abarca desde el 4 de enero del 2016 hasta el 5 de abril del 2021, con un total 1285 datos.
- Conjunto de validación: comprende desde el 6 de abril de 2021 hasta el 2 de julio de 2021, con un total de 61 datos.
- Conjunto de prueba: se extiende desde el 6 de julio hasta el 31 de diciembre de 2021, con un total 123 datos.

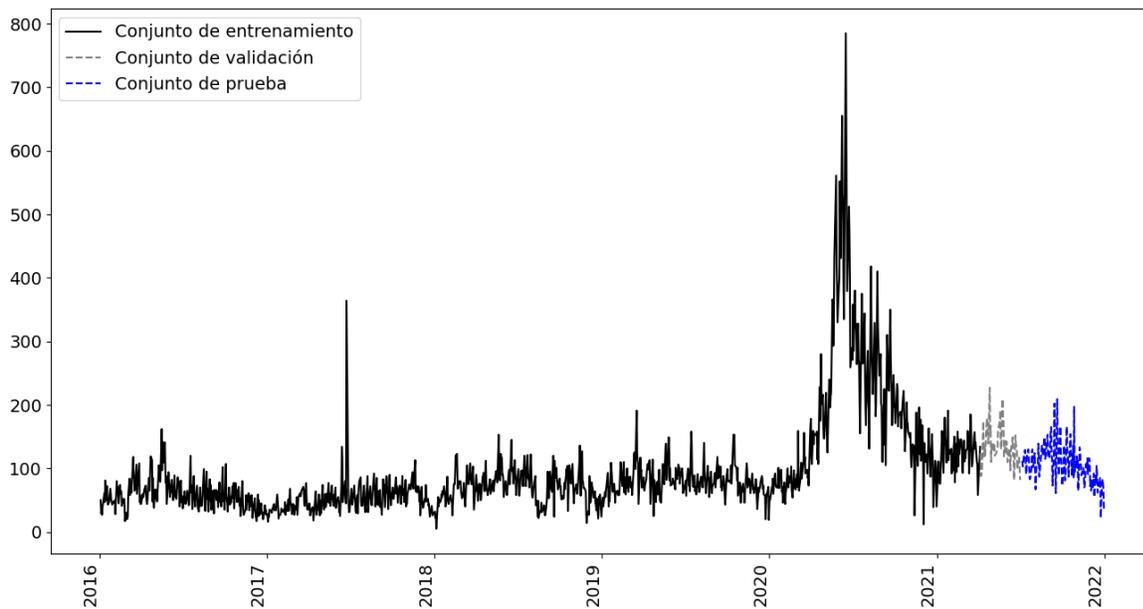


Figura 3-1 Conjunto de entrenamiento, validación y prueba

3.2 Criterios de evaluación

Para elegir el modelo que mejor se ajusta, es necesario contar con medidas que permitan comparar las diferentes configuraciones que estos pueden tener y con esto elegir el modelo que más se ajuste al problema dado (Medeiros, Vasconcelos, Veiga, & Zilberman, 2021).

- Error medio absoluto (MAE): es la diferencia absoluta media entre los resultados del modelo y las respuestas correctas (Willmott, 1982), como se representa en la Ecuación (3.1)

$$MAE = \frac{1}{N} \sum_{n=1}^N |y_n - \hat{y}_n| \quad (3.1)$$

Donde,

- N es el tamaño del conjunto de entrenamiento
- y_n es el valor n del conjunto de entrenamiento
- \hat{y}_n es el valor n del pronóstico

- Error cuadrático medio (MSE): es una medida de la desviación de las estimaciones y las observaciones (Fox, 1981). Se calcula con la ecuación (3.2):

$$MSE = \frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (3.2)$$

Donde,

- N es el tamaño del conjunto de entrenamiento
- y_n es el valor n del conjunto de entrenamiento
- \hat{y}_n es el valor n del pronóstico

- Error logarítmico cuadrático medio (MSLE): es una medida similar al MSE, pero utiliza el logaritmo para compensar los grandes valores atípicos en un conjunto de datos y los trata como si estuvieran en la misma escala. Al aplicar el logaritmo, los valores atípicos se reducen, lo que ayuda a que los errores sean más consistentes y comparables en diferentes escalas (Fox, 1981). Se calcula con la ecuación (3.3)

$$MSLE = \frac{1}{N} \sum_{n=1}^N (\log_e(1 + y_n) + \log_e(1 + \hat{y}_n))^2 \quad (3.3)$$

Donde,

- N es el tamaño del conjunto de entrenamiento
- y_n es el valor n del conjunto de entrenamiento
- \hat{y}_n es el valor n del pronóstico

- Error porcentual absoluto medio (MAPE): es una medida de la precisión de un sistema de pronóstico. Se utiliza para evaluar qué tan bien se ajustan los pronósticos a los valores reales. Se calcula como el error porcentual absoluto promedio para cada período de tiempo, es decir, la diferencia absoluta entre el valor pronosticado y el valor real, dividida por el valor real, y luego se promedia para todos los períodos (Fox, 1981). Se calcula con la ecuación (3.4)

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{|y_n - \hat{y}_n|}{\max(\epsilon, |y_n|)} \times 100\% \quad (3.4)$$

Donde,

- N es el tamaño del conjunto de entrentamiento
- y_n es el valor n del conjunto de entrenamiento
- \hat{y}_n es el valor n del pronóstico

- Coeficiente de determinación (R^2): es la proporción de la variación de la variable dependiente que puede ser explicada por las variables independientes incluidas en el modelo. Se interpreta como la proporción de la variación que logró ser explicada por las variables dependientes. El valor oscila entre 0 y 1, siendo los valores cercanos a 1 muestra de que el modelo explica la mayor parte de la variabilidad de la variable dependiente (Montgomery, Peck, & Vining, 2002). Se calcula con la ecuación (3.5)

$$R^2 = 1 - \frac{\sum(y_n - \hat{y}_n)^2}{\sum(y_n - \bar{y}_n)^2} \quad (3.5)$$

Donde,

- y_n es el valor n del conjunto de entrenamiento
- \hat{y}_n es el valor n del pronóstico

3.3 Modelo Autorregresivo recursivo

El primer modelo utilizado para el pronóstico de la serie de tiempo fue el Autorregresivo recursivo. En este caso, se utiliza únicamente la variable que se desea predecir como entrada y salida del modelo de predicción (Gujarati, 2011). Se empleó la función *ForecasterAutoreg* de la librería *skforecast*, con los siguientes parámetros:

- Ventana temporal de 14 observaciones: para cada predicción, se utilizaron como predictores la cantidad de reclamos de las 2 semanas anteriores.
- Regresor tipo *Ridge*: se utilizó con el propósito de reducir la varianza sin aumentar el sesgo, o que permitió obtener un menor error total.
- Se aplicó una transformación *StandardScaler* para estandarizar la variable antes de ajustar el modelo, asegurando así que todas las variables tuvieran la misma escala y evitando sesgos en los coeficientes del modelo.

Después del entrenamiento, se evaluó el rendimiento del modelo usando la función *backtesting_forecaster*. Posteriormente, se volvió a entrenar el modelo con el pronóstico obtenido previamente y se agregó el conjunto de validación que consta de 61 datos, lo que generó un dataframe con una longitud de 1346 datos. Utilizando este conjunto, se realizó una nueva predicción para los próximos 7 días y se repitió el proceso 18 veces para cubrir toda la serie, incluyendo tanto la serie agregada como cada uno de los ciclos de facturación. Como resultado de este proceso, se obtuvo un dataframe con los pronósticos para cada uno de los ciclos y el total del conjunto de prueba.

3.3.1 Optimización de los parámetros

Con el objetivo de encontrar la mejor combinación de parámetros para la función *ForecasterAutoreg*, se utilizó una técnica llamada *Grid Search*. Se entrenó un modelo para cada combinación de hiperparámetros del regresor y de los retardos utilizados como predictores, se evaluó la capacidad del modelo mediante la función *backtesting_forecaster* y al finalizar este proceso, el *forecaster* se reentrenó automáticamente con la mejor configuración encontrada y el conjunto de datos completo.

De los 40 resultados posibles, la combinación de los retardos [1, 2, 3, 4, 5, 6, 7] y el regresor *Ridge* con un $\alpha = 0.001$, obtuvo el menor Error Medio Absoluto $MAE = 22.46$, con estos nuevos parámetros se realizó un nuevo pronóstico. Este se comparó con la serie agregada y se calcularon las respectivas medidas de calidad para determinar qué modelo se ajusta mejor a los datos reales. Estos datos se analizarán al final de este capítulo.

3.4 Modelo ARIMA

El segundo modelo utilizado fue el ARIMA. Este modelo consiste en ajustar una curva a una serie de tiempo mediante la combinación de modelos autorregresivos, de medias móviles y una integración. La integración implica realizar diferenciaciones en la serie de tiempo para lograr que sea estacionaria. (Gujarati, 2011). Para el desarrollo de este se

utilizó la función *ForecasterSarimax* de la librería *skforecast*, con un regresor ARIMA de orden (14, 0, 0).

Después del entrenamiento, se evaluó el rendimiento del modelo usando la función *backtesting_sarimax*. Posteriormente, se volvió a entrenar el modelo utilizando el pronóstico obtenido previamente y se añadió el conjunto de validación. Utilizando el nuevo conjunto de datos, se realizó una nueva predicción para los siguientes 7 días y se repitió este proceso 25 veces para completar toda la serie, abarcando tanto la serie agregada como cada uno de los ciclos de facturación.

3.4.1 Optimización de los parámetros

Para este modelo también se buscó la mejor combinación de parámetros p , d y q con la función *grid_search_sarimax*. La combinación que mejor AIC obtuvo es el modelo (0, 1, 2), con un $AIC = 14129.21$.

Con estos nuevos parámetros se realizó un nuevo pronóstico, se comparó con la serie agregada y se calcularon las respectivas medidas de calidad para determinar qué modelo se ajusta mejor a los datos reales.

3.5 Comparación de modelos

En la Figura 3-2 se muestra una comparación entre los modelos AR, ARIMA y la serie agregada en el conjunto de prueba, que abarca desde el 6 de julio hasta el 31 de diciembre de 2021. Se puede observar que el modelo ARIMA se ajusta mejor, ya que captura la dinámica de la serie a lo largo del tiempo. Esta observación se refuerza con los datos de Tabla 3-1, donde se muestra que los valores más bajos de las medidas de calidad descritas en la sección 3.2, los cuales se obtuvieron con el modelo ARIMA.

Tabla 3-1 Comparación de errores de los modelos AR y ARIMA

Modelo	MAE	MSE	MSLE	MAPE	Error cuadrático
AR	19.30	669.67	0.07	20.79%	0.28
ARIMA	19.06	616.89	0.06	20.58%	0.34

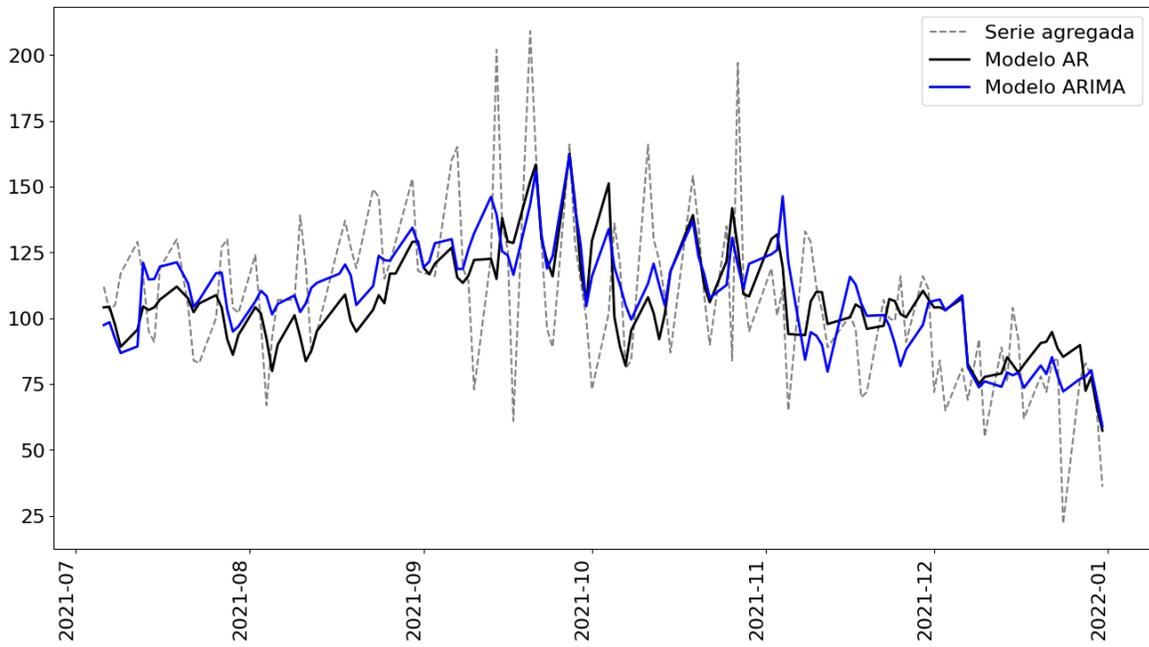


Figura 3-2 Comparación modelos vs serie agregada

4. Modelo con Redes Neuronales

En este Capítulo, al igual que en el Capítulo 3, se abordan dos Objetivos Específicos: el Objetivo Específico 2 que consiste en “Desarrollar un modelo tradicional de series de tiempo que permita el pronóstico de la serie agregada de reclamos diarios”; y el Objetivo Específico 3, que busca “Desarrollar un modelo de pronóstico que combine los pronósticos diarios de cada ciclo de facturación mensual”. Para esto lograr esto, se desarrollaron dos Modelos de Perceptrón Multicapa MLP para pronosticar la demanda. A lo largo de este capítulo se describirá la metodología usada y se presentaran graficas comparativas de los resultados obtenidos para seleccionar el pronóstico más preciso.

4.1 Red Neuronal

Una red neuronal es un conjunto de nodos interconectados que se basa en el comportamiento de una neurona biológica. Cada nodo se llama neurona y recibe información, que luego puede transmitir a otras neuronas. A su vez, cada neurona receptora asigna cierta importancia a la información recibida, lo cual se conoce como peso. Las neuronas pueden agruparse en capas para formar una red neuronal, y se considera que una red es más profunda cuando tiene más capas (Hilera González & Martínez Hernando, 1994).

En este caso de estudio se utilizó un Perceptrón Multicapa o MLP (Multilayer Perceptron en inglés). El MLP es una generalización del perceptrón simple, que consta de más de un nivel de neuronas y/o de una o varias capas de neuronas entre la capa de entradas y la capa de salidas. Estas capas intermedias se conocen como capas ocultas y pueden tener funciones de activación no lineales entre ellas. El MLP es capaz de aprender y representar

relaciones no lineales en los datos, lo que lo hace adecuado para problemas de pronóstico y clasificación más complejos (Gajowniczek & Ząbkowski, 2018)

4.2 Modelo 1: serie sin transformar

En el primer modelo, se realizó el escalado de la serie de tiempo en el intervalo $[0,1]$, con el objetivo de facilitar el entrenamiento del modelo. Para ello, se utilizó la función *MLPRegressor* de la librería *sklearn.neural_network*, con los siguientes parámetros:

- *hidden_layer_sizes*: una capa oculta con 5 neuronas.
- *Activation*: función de activación *logistic*.
- *learning_rate*: mantiene constante el valor especificado en el argumento *learning_rate_init*, que para este caso fue 0.1

Después de completar el entrenamiento del modelo y generar el pronóstico, se realizó el proceso de desescalado para volver a los valores originales de la serie de tiempo. Este paso es necesario para que el pronóstico sea interpretable y comparable con los valores reales.

4.3 Modelo 2: serie transformada

En el segundo modelo, se llevó a cabo la remoción de la tendencia y el componente cíclico de la serie de tiempo, como se explicó en la sección 4.2. Posteriormente, se realizó el escalado de la serie de tiempo en el intervalo $[0,1]$. Para este modelo, se utilizaron los mismos parámetros en la función *MLPRegressor* que en el primer modelo mencionado, es decir:

- *hidden_layer_sizes*: una capa oculta con 5 neuronas. optimizado
- *Activation*: función de activación *logistic*.
- *learning_rate*: mantiene constante el valor especificado en el argumento *learning_rate_init*, que para este caso fue 0.1

El objetivo de este segundo modelo era ajustar un MLP a la serie de tiempo procesada, utilizando los mismos parámetros que en el primer modelo. Esto permitiría comparar el desempeño de ambos en términos de precisión del pronóstico.

4.4 Comparación de modelos

En la Figura 4-1 se presenta una comparación entre los modelos MLP de la serie transformada y sin transformar, junto con la serie agregada en el conjunto de prueba, que abarca desde el 6 de julio hasta el 31 de diciembre de 2021. Al analizar la figura, se puede observar que el pronóstico generado por el modelo MLP de la serie sin transformar se ajusta mejor en comparación con el modelo MLP de la serie transformada.

Además, al referirse a las medidas de calidad descritas en la sección 3.2 y mostradas en la tabla 4-1, se encontró que el modelo MLP de la serie sin transformar obtuvo los valores más bajos en dichas medidas. Esto sugiere que el modelo MLP aplicado a la serie sin transformar es más preciso en el pronóstico de la demanda diaria de reclamos.

Esta comparación y análisis de los resultados respaldan la elección del modelo MLP de la serie sin transformar como el que proporciona los mejores resultados en términos de ajuste y precisión en la predicción.

Tabla 4-1 Comparación de errores de los modelos de la serie transformada y sin transformar

Modelo	MAE	MSE	MSLE	MAPE	Error cuadrático
Serie sin transformar	22.55	811.34	0.08	25.69%	0.13
Serie transformada	38.13	2391.25	0.22	37.73%	0.27

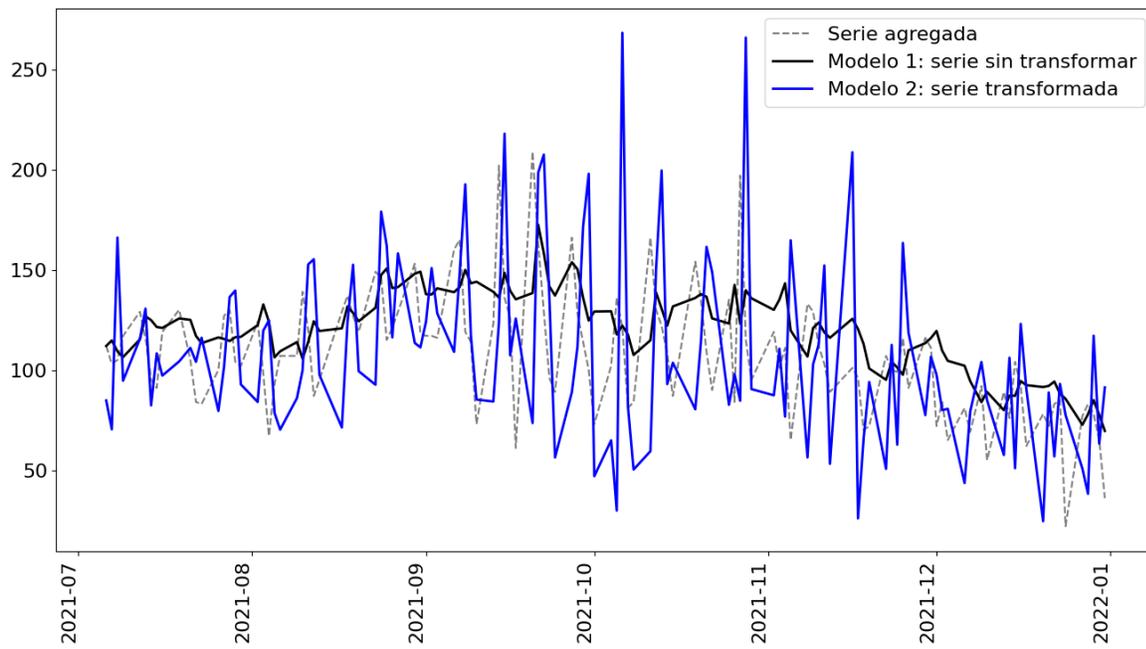


Figura 4-1 Comparación modelos vs serie agregada

5. Elección del modelo y Prototipo de simulación

En este capítulo, se mostrarán los resultados obtenidos con los diferentes modelos de pronóstico desarrollados. Se evaluará el desempeño de cada modelo en función de los KPI establecidos, como el tiempo de respuesta y la cantidad de reclamos pendientes de atención.

Posteriormente, se presentará la elección del mejor modelo de pronóstico basado en su precisión y capacidad para predecir la demanda de reclamos de manera efectiva.

Además, se describirá el prototipo de simulación desarrollado y cómo se utilizó para ajustar la cantidad de personal necesario. Este prototipo permitirá garantizar un cumplimiento óptimo de los KPI establecidos y mejorar la atención de los reclamos en términos de tiempo de respuesta y cantidad de reclamos pendientes de atención.

5.1 Elección del mejor modelo de pronóstico

Para la elección del mejor modelo de pronóstico, se realizaron comparaciones utilizando las medidas de calidad obtenidas en los Capítulos 3 y 4 para los modelos Autorregresivo, ARIMA y Redes Neuronales.

Después de analizar y evaluar las medidas de calidad, se puede concluir que el modelo ARIMA obtuvo los mejores valores de error en las medidas de MAE (Mean Absolute Error), MASE (Mean Absolute Scaled Error), MSLE (Mean Squared Logarithmic Error) y MAPE (Mean Absolute Percentage Error). Estos resultados indican que el modelo ARIMA fue el

más preciso en la predicción de la demanda diaria de reclamos, demostrando un desempeño superior en comparación con los otros modelos evaluados. Estos resultados se presentan en detalle en la Tabla 5-1 y el ajuste del pronóstico en la Figura 5-1.

Tabla 5-1 Comparación de errores de los modelos desarrollados

Modelo	MAE	MSE	MSLE	MAPE	Error cuadrático
AR	19.30	669.67	0.07	20.79%	0.28
ARIMA	19.06	616.89	0.06	20.58%	0.34
MLP_1	22.55	811.34	0.08	25.69%	0.13
MLP_2	38.13	2391.25	0.22	37.73%	0.27

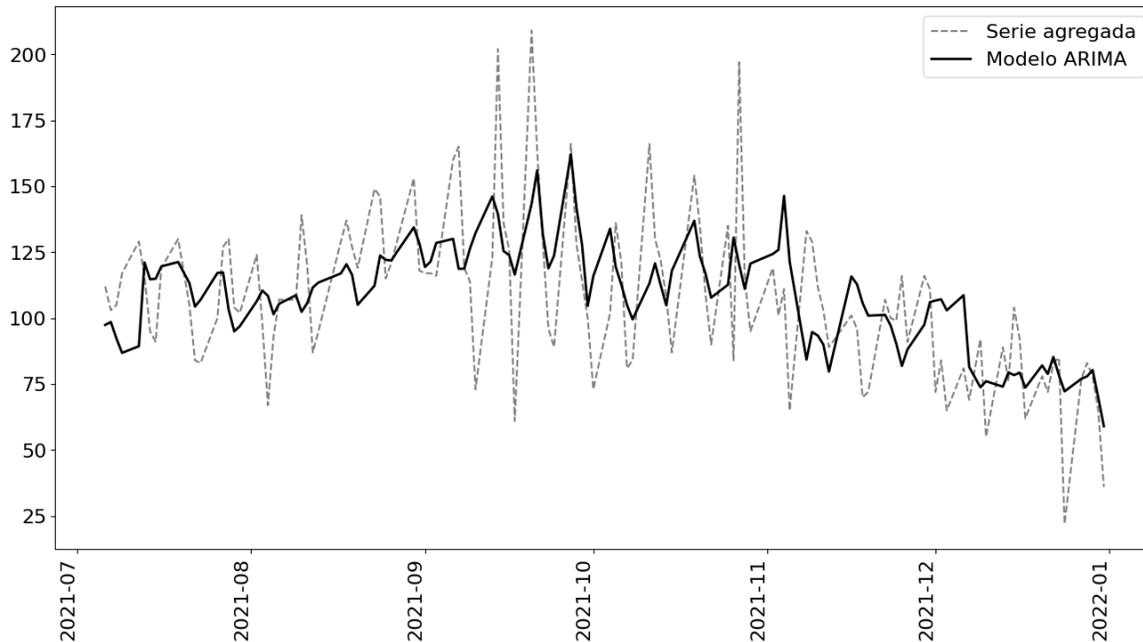


Figura 5-1 Comparación de la serie agregada y el pronóstico con el modelo ARIMA

5.2 Prototipo de simulación

Se desarrolló un sistema de simulación de las transacciones que ejecuta el proceso típico que un reclamo tendría desde que es radicado por el cliente hasta que se emite la

respuesta. Este sistema tiene en cuenta los siguientes estados, como se muestran en la Figura 5-2:

1. Abierto (Open): Este estado se asigna a los reclamos cuando los clientes hacen uso de alguno de los canales de atención y los reclamos ingresan al sistema.
2. Asignado (Assigned): En este estado, el reclamo fue asignado a uno de los funcionarios de los equipos especializados, por alguno de los encargados de direccionar las transacciones. Es importante tener en cuenta que estos funcionarios tienen una capacidad limitada de asignación.
3. En progreso (In progress): Cuando el funcionario del equipo especializado está realizando el análisis respectivo para proporcionar una respuesta adecuada, el reclamo se encuentra en este estado.
4. Cerrado (Closed): Una vez que se completa la atención y se emite la respuesta al reclamo, este pasa al estado de "Cerrado". El funcionario luego tomará el siguiente documento en estado "Asignado" de la pila de documentos asignados. Es posible que una persona tenga varios documentos en estado "En progreso" simultáneamente, y el tiempo de gestión puede variar dependiendo de cada caso puntual.

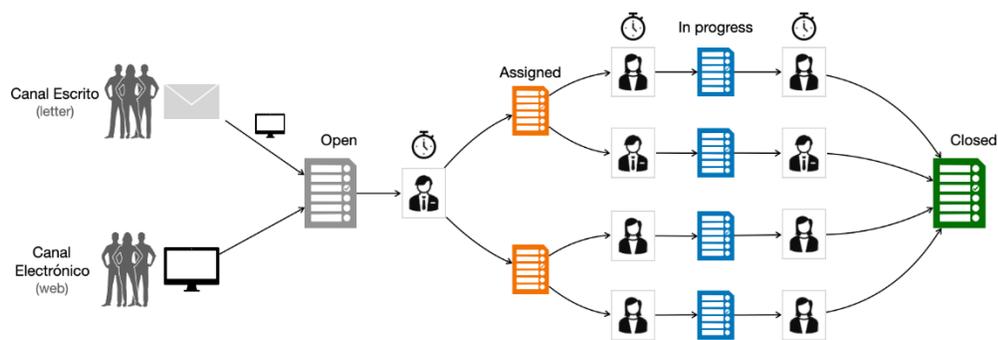


Figura 5-2 Flujo de trabajo – Tomado de (Velasquez Henao, 2022)

La unidad de tiempo de la simulación es el día, pero el sistema entrega resultados semanales. Genera una base de datos que contiene los siguientes campos:

- Un código único asignado a cada reclamo.
- La fecha en la que el cliente presentó el reclamo al sistema.
- El número de días hábiles que se requirieron para completar el proceso de atención del reclamo, desde su presentación hasta su cierre.
- La fecha en la que el reclamo fue asignado al equipo especializado para su análisis y atención.
- La fecha en la que se emitió la respuesta final al reclamo y se cerró el proceso de atención.

Estos campos proporcionan información relevante sobre cada reclamo atendido en el sistema de simulación, incluyendo la duración del proceso y las fechas clave asociadas a cada etapa. Esta base de datos puede ser utilizada para análisis posteriores, seguimiento de tiempos de atención, identificación de tendencias y mejoras en el proceso de atención de reclamos.

5.3 Simulación del pronóstico y comparación con la serie real

En el sistema desarrollado, se realizaron dos simulaciones para el intervalo de tiempo del 6 de julio al 31 de diciembre de 2021, que abarca un total de 26 semanas. Estas simulaciones permiten analizar el flujo de reclamos y la gestión del personal en dos escenarios diferentes:

Primera simulación: en este escenario, se utilizan los datos reales de la serie de reclamos para representar los reclamos que llegan día a día. El sistema corre sin tener pronósticos disponibles de los reclamos que podrían llegar en las siguientes semanas. En otras palabras, se simula la operación actual del sistema donde las decisiones son reactivas. En este caso, la gestión del personal para la respuesta de los reclamos se realiza una vez que se tienen evidencias de que el sistema se está saturando.

Segunda simulación: en esta simulación, también se utilizan los datos de la serie real como entradas para representar la llegada de los reclamos. Sin embargo, para cada semana, se computan los pronósticos de la cantidad de reclamos que llegarán en las siguientes semanas. Esto permite gestionar el personal que atiende los reclamos en base a los pronósticos, de manera proactiva. En este escenario, se pueden tomar decisiones anticipadas para ajustar la capacidad de trabajo según las demandas esperadas.

Para cada día dentro del periodo de simulación, se registraron los datos relevantes del proceso de reclamos, que incluyen la cantidad de transacciones en los estados de "asignado", "en progreso" y "cerrado", así como el tiempo de respuesta.

Estas dos simulaciones permiten comparar la operación reactiva y la operación proactiva del sistema de atención de reclamos. El análisis de los resultados de ambas simulaciones brinda información valiosa para evaluar el impacto de la gestión del personal basada en pronósticos y determinar si el uso de los pronósticos para la toma de decisiones mejora los indicadores de proceso a lo largo del tiempo.

En la Figura 5-3 se presenta la cantidad de reclamos en estado "en progreso" tanto en la serie agregada como en el pronóstico realizado. Se observa una disminución promedio del 17% entre ambas series. Esta reducción es posible debido a que, al conocer de antemano la cantidad de transacciones que ingresarán semana a semana, se puede ajustar la cantidad de funcionarios necesarios en el equipo. Al aumentar la fuerza laboral, se logra disminuir las transacciones pendientes de respuesta en el estado "en progreso".

Esta disminución en la cantidad de reclamos en estado "en progreso" es un indicativo de una mejora en la eficiencia del proceso de atención de reclamos. Al ajustar la capacidad de trabajo según las demandas esperadas, se logra mantener un flujo de trabajo más ágil y reducir la cantidad de reclamos pendientes de atención.

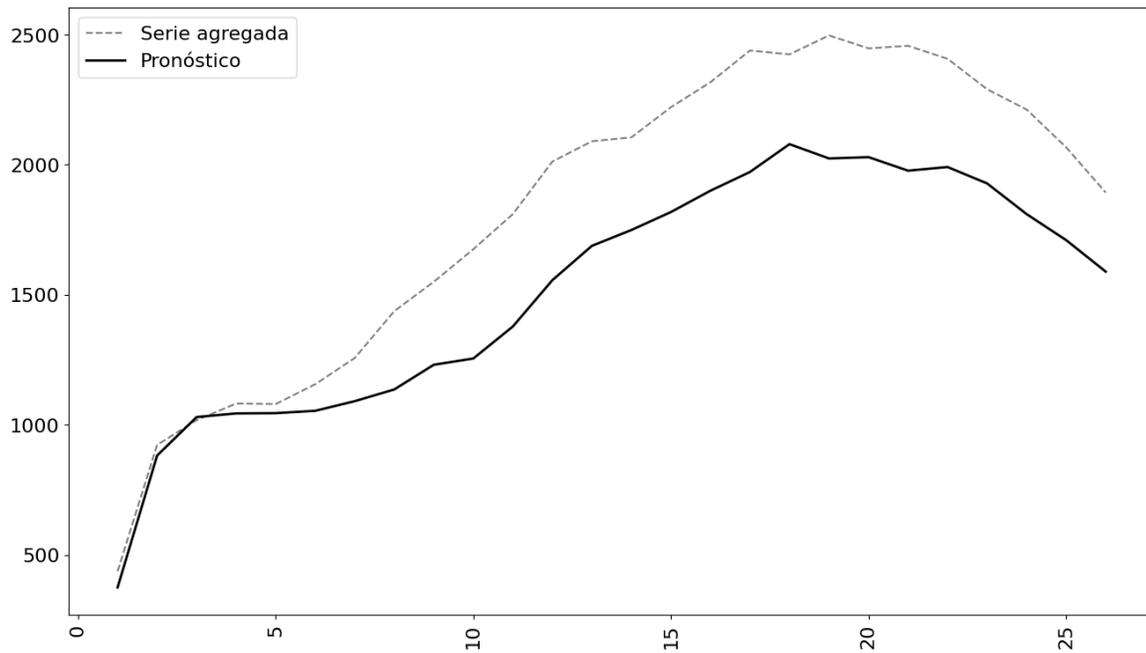


Figura 5-3 Comparación de los reclamos “en progreso” de la serie agregada y el pronóstico

De acuerdo con esto, la Figura 5-4 muestra la reducción de los tiempos de respuesta para estas transacciones. Esto indica que al disminuir la cantidad de reclamos en estado "en progreso" y mantener un flujo de trabajo eficiente, se logra una respuesta más rápida a los reclamos presentados por los clientes.

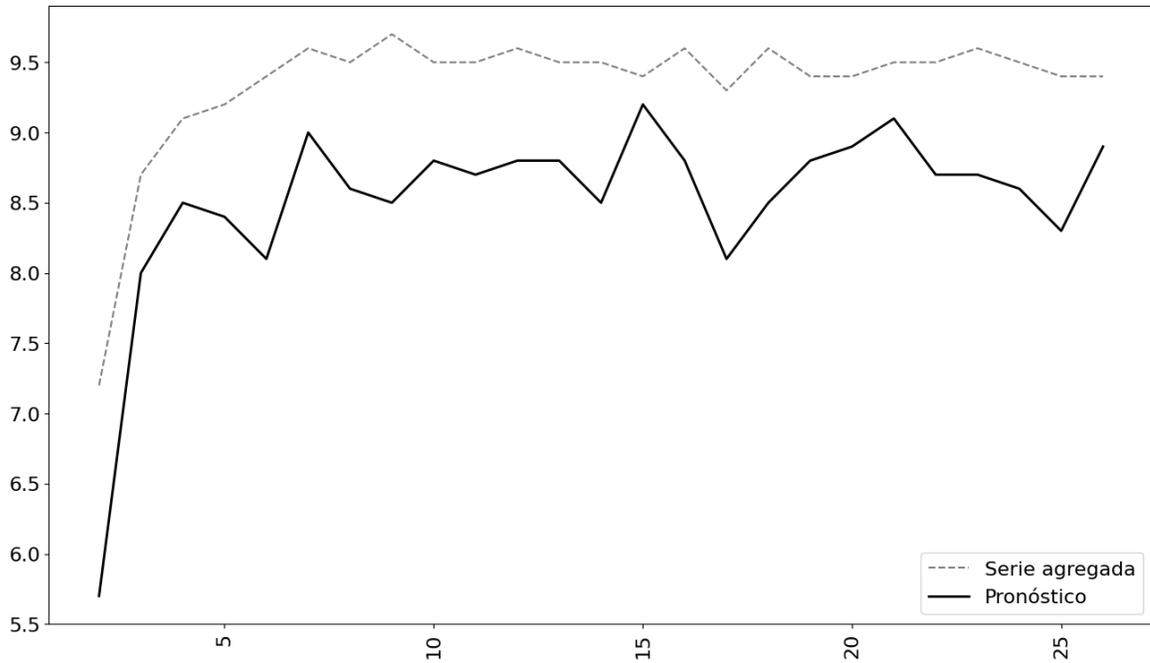


Figura 5-4 Comparación de los tiempos de respuesta de la serie de agregada y el pronóstico

En la Figura 5-5 se presenta una comparación entre la serie agregada y el pronóstico de la cantidad de transacciones atendidas en diferentes intervalos de tiempo: menos de 10 días, 11 días, 12 días, 13 días, 14 días y 15 días. Al ajustar la cantidad de personal necesario para atender la cantidad de reclamos según el pronóstico, se observa una clara disminución en la cantidad de transacciones atendidas en más de 10 días y un aumento en aquellas atendidas en menos de 10 días, en comparación con la serie agregada.

Estos resultados respaldan la efectividad del sistema de simulación y la capacidad de ajustar la fuerza laboral para mejorar tanto la cantidad de reclamos pendientes como los tiempos de respuesta, cumpliendo así con los indicadores de proceso establecidos.

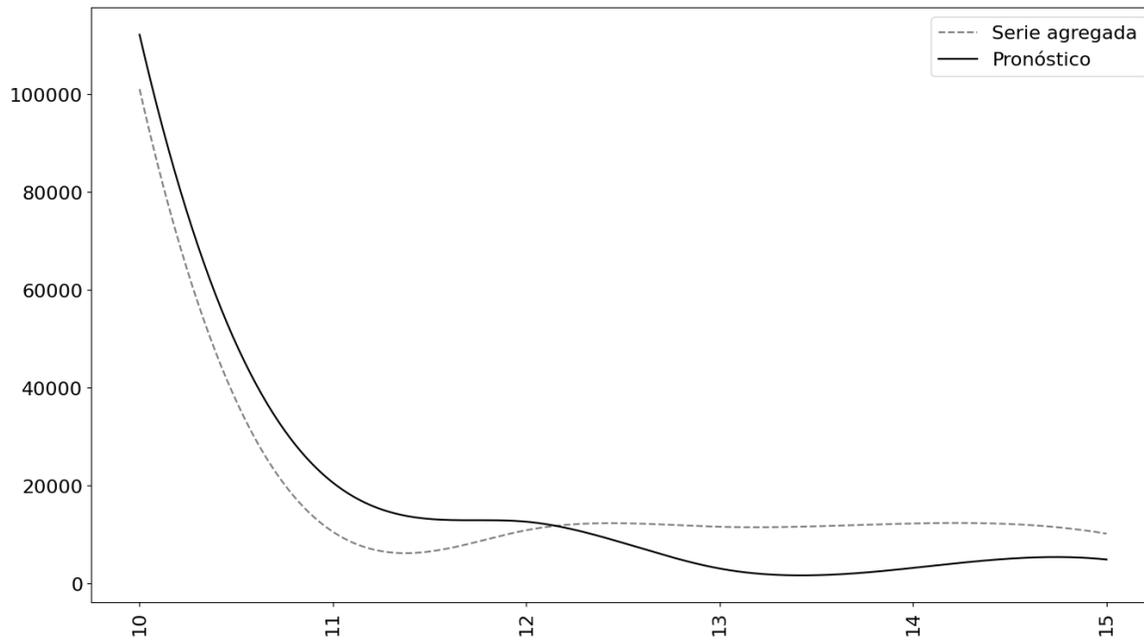


Figura 5-5 Comparación de la cantidad de transacciones atendidas vs tiempo, para la serie agregada y el pronóstico

6. Conclusiones y recomendaciones

6.1 Respuesta a la hipótesis

La hipótesis planteada en la sección 1.5 del Capítulo 1, fue la siguiente: ¿Es posible desarrollar un modelo de pronóstico para determinar la cantidad futura de reclamos que ingresan diariamente por el canal escrito en las empresas de servicios públicos domiciliarios, con el fin de tomar decisiones?

Los resultados obtenidos en el Capítulo 5, muestran que se desarrollaron cuatro modelos de pronóstico y, en base a las medidas de calidad descritas en la sección 3.2 del Capítulo 3 se determinó que el modelo que mejor se ajustaba era el modelo ARIMA.

6.2 Cumplimiento de objetivos

Este trabajo tiene como objetivo general “Desarrollar modelos para pronosticar la cantidad de reclamos diarios que ingresan al canal escrito, y que permitan comparar diferentes aproximaciones al problema”.

Para alcanzar este se llevaron a cabo tres objetivos específicos, cuyos cumplimientos están descritos a continuación:

6.2.1 Objetivo específico 1

Realizar el análisis exploratorio de los datos con el fin de determinar que consideraciones deberían tenerse en cuenta para construir modelos que permitan pronosticar la cantidad de reclamos que ingresan por el canal escrito.

En el Capítulo 2 se llevó a cabo el análisis exploratorio de la serie de tiempo, en el cual se describió su comportamiento y se explicó la razón de los datos atípicos encontrados. Se realizaron gráficos que representaron los 21 ciclos de facturación presentes en la serie.

Se aplicó la prueba de Dickey-Fuller Aumentada (ADF) para determinar si la serie era estacionaria. Los resultados de la prueba indicaron que la serie poseía estacionariedad, lo que implica que no presentaba tendencias ni patrones de cambio significativos en el tiempo.

También se realizaron gráficos de las componentes de la serie de tiempo utilizando el modelo aditivo. Se examinó la distribución mensual, diaria y semanal de la cantidad de reclamos, lo que permitió identificar posibles patrones estacionales o variaciones en los datos a lo largo de estos periodos.

6.2.2 Objetivo específico 2 y 3

2. *Desarrollar un modelo tradicional de series de tiempo que permita el pronóstico de la serie agregada de reclamos diarios.*
3. *Desarrollar un modelo de pronóstico que combine los pronósticos diarios de cada ciclo de facturación mensual.*

En los Capítulos 3 y 4, se desarrollaron modelos de pronóstico para el período comprendido entre el 6 de julio y el 31 de diciembre de 2021 utilizando dos fuentes de

información: la serie agregada de reclamos diarios y los datos para los 21 ciclos de facturación. En el Capítulo 3, se utilizaron los modelos Autorregresivos (AR) y ARIMA y en el Capítulo 4, dos modelos de redes neuronales, el primero usando la serie transformada y el segundo la serie sin transformar. Con estos modelos se desarrollaron dos modelos de pronóstico: uno para la serie agregada y otro que era el resultado de la sumatoria de los pronósticos para cada ciclo de facturación. Para cada uno de estos modelos, se optimizaron los parámetros con el objetivo de encontrar aquellos que brindaran un mejor pronóstico.

Posteriormente, se calcularon las medidas de calidad y se compararon los cuatro modelos. Los resultados mostraron que el modelo ARIMA tenía los mejores valores en las medidas de calidad, destacando como el más adecuado, presentando el mejor ajuste a la dinámica de la serie de tiempo, capaz de capturar de manera más precisa la variabilidad y los patrones presentes en la serie de reclamos diarios.

6.3 Recomendaciones y trabajo futuro

Se recomienda realizar el entrenamiento del modelo utilizando datos correspondientes al año 2022, ya que el aprendizaje que el modelo adquiera a partir de estos datos puede mejorar su capacidad de pronóstico. Además, se sugiere pronosticar en un horizonte de 15 días. Con esta ventana de tiempo, el prototipo de simulación podría determinar la cantidad óptima de personal necesaria para atender la cantidad de transacciones durante ese período específico, esto facilita una planificación efectiva y ayuda a garantizar una gestión eficiente de los reclamos, optimizando los recursos disponibles y minimizando los tiempos de espera para los clientes

Es importante destacar que el uso de datos actualizados y relevantes para el entrenamiento del modelo mejora su precisión y capacidad de generalización en la realización de pronósticos. Al considerar los datos del año 2022, se brinda al modelo la oportunidad de aprender y capturar las tendencias y patrones más recientes en los reclamos y transacciones. Esto puede resultar en pronósticos más precisos y confiables para el período de tiempo específico en cuestión.

7. Bibliografía

- Assaf, S., & Srour, I. (2021). Using a data driven neural network approach to forecast building occupant complaints. *Building and Environment*, 200. Obtenido de <https://doi.org/10.1016/j.buildenv.2021.107972>
- Chehade, A., Savargaonkar, M., & Krivtsov, V. (2022). Conditional Gaussian mixture model for warranty claims. *Reliability Engineering and System Safety*, 218. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0951832021006645>
- Donghui, W. (2017). A big data analytics framework for forecasting rare customer complaints: A use case of predicting MA members' complaints to CMS. *Proceedings - 2017 IEEE International Conference on Big Data, Big Data 2017*, (págs. 3965-3967).
- Fox, D. G. (1981). Judging Air Quality Model Performance: A Summary of the AMS Workshop on Dispersion Model Performance, Woods Hole, Mass., 8–11 September 1980. *Bulletin of the American Meteorological Society*, 599 - 609. Obtenido de https://journals.ametsoc.org/view/journals/bams/62/5/1520-0477_1981_062_0599_jaqmp_2_0_co_2.xml
- Gajowniczek, K., & Ząbkowski, T. (2018). Simulation Study on Clustering Approaches for Short-Term Electricity Forecasting. *Complexity*, vol. 2018, 21. Obtenido de <https://doi.org/10.1155/2018/3683969>
- Gujarati, D. N. (2011). *Econometría básica*. McGraw Hill Brasil.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson.
- Hilera González, J. R., & Martínez Hernando, V. J. (1994). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. SERBIULA (sistema Librum 2.0).
- Medeiros, M., Vasconcelos, G., Veiga, Á., & Zilberman, E. (2021). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business & Economic Statistics*, 1-22. Obtenido de <https://doi.org/10.1080/07350015.2019.1637745>

- Montgomery, D. C., Peck, E. C., & Vining, G. G. (2002). *Introducción al análisis de regresión lineal*. Compañía Editorial Continental.
- Qi, M., & Zhang, G. P. (2001). An investigation of model selection criteria for neural network time series forecasting. *European Journal of Operational Research*, 666-680. Obtenido de [https://doi.org/10.1016/S0377-2217\(00\)00171-5](https://doi.org/10.1016/S0377-2217(00)00171-5).
- Shaomin, W., & Akbarov, A. (2012). Forecasting warranty claims for recently launched products. *Reliability Engineering and System Safety*, 160-164. Obtenido de <https://doi.org/10.1016/j.ress.2012.06.008>
- Velasquez Henao, J. D. (4 de 5 de 2022). *Cursos de Analítica y Machine Learning*. Obtenido de https://jdvelasq.github.io/courses/modulos/dataops%20pqrs/parte%201/notebooks/1-01_simulacion_rdbms.html
- Willmott, C. J. (1982). Some Comments on the Evaluation of Model Performance. *Bulletin of the American Meteorological Society*, 1309–1313. Obtenido de [https://doi.org/10.1175/1520-0477\(1982\)063<1309:SCOTEO>2.0.CO;2](https://doi.org/10.1175/1520-0477(1982)063<1309:SCOTEO>2.0.CO;2)