

**¿Es posible pronosticar el precio por kilogramo en el mercado porcícola como una herramienta de gestión de riesgo?**

Por

Juan Camilo Zapata Bustamante

Tesis presentada como requisito para obtener el título de Magíster en Administración  
Financiera

Asesor

Vivian Cruz Castañeda

UNIVERSIDAD EAFIT

Medellín, Abril, 2023

## **Resumen**

Dada la alta volatilidad en el precio por kilogramo (COP/kg) en el mercado porcícola, se busca desarrollar un modelo predictivo que sirva como herramienta para la gestión del riesgo por parte de los productores. El propósito de este trabajo es proporcionar una guía estratégica que permita identificar el mejor momento para la venta de lotes, organizar la producción en consecuencia y establecer condiciones favorables en los contratos de venta. Desarrollar un modelo para predecir el precio por kilogramo en el mercado porcícola permitiría contar con una herramienta óptima para la gestión del riesgo desde la perspectiva de los productores. Para alcanzar este objetivo, se empleará la metodología de Box Jenkins, utilizando como base el modelo ARIMA para anticipar las posibles fluctuaciones de los precios en el mercado porcícola, permitiendo a los productores tomar decisiones fundamentadas y, de este modo, maximizar los rendimientos de sus operaciones en el mercado colombiano.

## **Palabras clave**

Riesgo de mercado, Gestión de riesgo, Series de tiempo, Mercado porcícola.

## **Abstract**

Due to the high volatility on the price per kilogram (COP/kg) in the pork market, the development of a predictive model as a risk management tool for producers is sought. The purpose of this tool is to provide a strategic guide to identify the best moment to sell a batch, organize the production accordingly and establishing favorable conditions in selling contracts. This could provide an optimal risk management tool from the producer's perspective in the market. To achieve this, the Box Jenkins methodology will be employed, using the ARIMA model as a base. The main objective its to anticipate possible fluctuations in the pig market, allowing producers to take informed decisions and in consequence, maximize de returns in the Colombian market operations.

## **Key words**

Market risk, Risk management, Time series, Pig market.

## Contenido

Introducción.....	1
Revisión de la literatura.....	4
Metodología y datos .....	7
Datos.....	9
Estadísticas Descriptivas.....	10
Resultados.....	12
Prueba de Robustez: Análisis de escenarios .....	21
Recomendaciones en la Gestión de riesgo del mercado porcícola a partir de la modelación del precio por kg/COP de la carne.....	26
Conclusiones.....	28
Recomendaciones.....	30
Referencias .....	32

## Índice de figuras

Figura 1 Histograma de la serie.....	10
Figura 2 Datos históricos del precio por kilogramo .....	12
Figura 3 Tendencia de la serie.....	13
Figura 4 Estacionalidad de la serie. ....	14
Figura 5 Residuales de la serie de tiempo diferenciada una vez. ....	15
Figura 6 Gráfico de autocorrelación parcial de la serie diferenciada. ....	15
Figura 7 Gráfico de autocorrelación de la serie diferenciada. ....	16
Figura 8 Gráfico de división de la serie entre train y test.....	17
Figura 9 Gráfico PACF para componentes estacionales de la serie. ....	18
Figura 10 Gráfico ACF para componentes estacionales de la serie. ....	18
Figura 11 Gráfico de pronóstico de modelo ARIMA(1,1,1). ....	20
Figura 12 Gráfico de pronóstico del modelo SARIMA(2,1,1)(1,0,0) <sup>52</sup> . ....	20
Figura 13 Gráfico de escenario de concavidad.....	23
Figura 14 Gráfico de pronóstico en escenario de concavidad.....	23
Figura 15 Gráfico de escenario de convexidad. ....	24
Figura 16 Gráfico de pronóstico en escenario de convexidad.....	25

## Índice de tablas

Tabla 1 Análisis descriptivo de la serie.....	11
Tabla 2 Comparación de los modelos ARIMA y SARIMA propuestos. ....	19
Tabla 3 Métricas para el escenario base. ....	22
Tabla 4 Métricas para el escenario de concavidad. ....	24
Tabla 5 Métricas para el escenario de convexidad.....	26

## Índice de ecuaciones

Ecuación 1 Modelo AR .....	7
Ecuación 2 Modelo MA .....	7
Ecuación 3 Modelo ARIMA.....	8
Ecuación 4 Error RMSE .....	8
Ecuación 5 Error MAPE.....	8

## Introducción

La ganadería es una práctica milenaria que comprende la administración y crianza de múltiples especies de animales, que va desde el mundo de los mamíferos como el ganado bovino hasta aves como las gallinas, incluyendo reptiles, peces y artrópodos que son domesticados o mantenidos en cautiverio con el fin de satisfacer las necesidades humanas, principalmente asociadas a la alimentación (Myers , 1998).

Este estudio se centrará en el ganado porcino, una rama fundamental en la ganadería, la cual enmarca numerosas actividades a lo largo de la cadena productiva del cerdo, como crianza, engorde y comercialización. El ganado porcino, compuesto por múltiples razas como Pietrain, Duroc, Landrace, Hamp Shire, entre otros, representa un papel fundamental en la industria alimentaria debido a que es una fuente importante para el suministro cárnico y a los múltiples usos de su piel y sistema óseo, contando los ejemplares con un peso promedio de 116.6 kg (PorkColombia,2022). Para el caso colombiano, en promedio el consumo per cápita de cerdo fue de 10.8 kilogramos por habitante en el año 2020 (Minagricultura,2020).

PorkColombia es la asociación que representa a los productores de cerdo, fundada en 1983. Esta asociación presenta boletines semanales en los que publica los precios por kilogramo en pie y en canal, los cuales son un insumo para las negociaciones de la producción porcícola. De acuerdo con el Informe de Gestión de 2022 de PorkColombia, el sector porcícola fue uno de los sectores que más aportó al PIB agropecuario, con un crecimiento del 8.5% en el último trimestre del año. Durante el año 2022, el sector porcícola aportó 6.11 billones de pesos a la economía y posicionó a Colombia como el país número 17 a nivel mundial en producción porcícola con un 0.5% de participación en la producción mundial (Asociación PorkColombia,2022). Esta participación en la producción mundial, se enfoca en consumo nacional y exportaciones principalmente a Costa de Marfil y Hong Kong.

Según el informe de Cifras Sectoriales del Ministerio de Agricultura y Desarrollo Rural del país, en 2020, la porcicultura generó 150.000 trabajos directos, con una participación

del 43.4% en la producción para Antioquia, participación significativamente superior a la de las otras regiones (Minagricultura,2020).

El reto que enfrentan los porcicultores es lograr una venta de su producción a un precio por kilogramo que represente utilidades. Este reto se debe a la volatilidad que se presenta en estos precios, los cuales pueden afectar negativamente los resultados de la venta del cerdo. Adicionalmente, en Colombia la ganadería tiene una gran componente empírica, por lo cual la gestión del riesgo o la definición de una operación organizada son temas desconocidos o ignorados.

Como se indicó anteriormente, los boletines publicados por PorkColombia, incluyen precios calculados a partir de información brindada por porcicultores en las diferentes regiones del país, los cuales son usados como referente en las negociaciones de lotes porcícolas. El riesgo asociado a este referente es que, si el valor publicado para una semana en la cual se pretende realizar una transacción es muy bajo, puede llevar al productor a presentar pérdidas. Al realizar una gestión del riesgo del precio, el productor podría anticiparse e intentar vencer el mercado por medio del análisis realizado o tomar decisiones frente a la producción del cerdo para lograr venderlos en el momento más adecuado.

Dada la importancia del sector y la variabilidad en los precios, una herramienta propuesta para la administración del riesgo de la volatilidad del precio por kilogramo del cerdo es el uso de metodologías que modelen la serie de tiempo de los precios semanales y tratar de pronosticar su comportamiento con el objetivo de anticiparse a situaciones de mercado que puedan ser descritas a partir de los modelos propuestos.

En el boletín mensual del Ministerio de Agricultura y Desarrollo Rural, “INSUMOS Y FACTORES ASOCIADOS A LA PRODUCCIÓN AGROPECUARIA” se establece que el periodo de ceba de un cerdo puede darse alrededor de los 150 días, es decir 20 semanas (Minagricultura, 2013). Para un productor porcícola que está próximo a comenzar el periodo de ceba de su lote, sería de gran utilidad tener idea del comportamiento del mercado cuando pase el tiempo anteriormente mencionado para estimar sus ventas por el lote cebado. Con base en lo anterior, la prueba de éxito del modelo será lograr predecir como mínimo 20 datos de la serie

El objetivo general del estudio es modelar y pronosticar el precio de la carne de cerdo en el mercado colombiano utilizando los modelos ARIMA Y SARIMA. También se analizará la exactitud y robustez de las predicciones mediante la evaluación de los errores de los modelos. Este análisis ayudará a determinar qué modelo permite minimizar los errores de predicción y puede apoyar el proceso de toma de decisiones en la industria porcina. El estudio se dividirá en dos partes de acuerdo al objetivo general planteado y orientadas a la toma de decisiones en el sector

El primer objetivo específico es encontrar un modelo estadístico que permita modelar y realizar pronósticos del precio por kilogramo del cerdo con una precisión aceptable que le permita a los productores tomar decisiones informadas y de esta manera anticiparse a los posibles cambios en el mercado. Además se evaluará la capacidad de predicción de cada modelo comparando su precisión.

El segundo objetivo específico es proponer alternativas para la gestión del riesgo basada en la información obtenida en el modelo de la serie de tiempo de los precios, para lograr la maximización de rendimientos y reducción del riesgo en este mercado.

## Revisión de la literatura

Este estudio propone modelar los precios de la carne del cerdo como herramienta de pronóstico y gestión del riesgo para la toma de decisiones. Algunos autores han modelado el precio del kg de cerdo utilizando diversas metodologías. Es el caso de Zielińska-Sitkiewicz & Chrzanowska (2021) que utiliza un modelo ARIMA para predecir los precios del cerdo en Polonia. Para parametrizar el modelo se considera la estacionariedad de la serie y las funciones de autocorrelación y autocorrelación parcial. Además utilizan un modelo SARIMA para modelar la serie dado su comportamiento estacional, alcanzando obtener errores de pronóstico ex post inferiores al 4% .

Además Mo (2019), utiliza un modelo GARCH para estimar la volatilidad y fluctuación de los precios mensuales del cerdo, el maíz y el concentrado, desde el año 2000 hasta el 2019. De las variables analizadas, se determina que la única que presenta una condición de alta volatilidad y altos retornos es el precio del cerdo . Este estudio tiene gran importancia ya que en el contexto chino, el cerdo es un producto esencial de la economía, siendo China el país con la mayor producción y consumo de cerdo del mundo

Como metodología de gestión agrícola en China y con el objetivo de maximizar rendimientos, Wang (2019), realiza el pronóstico de corto plazo del precio del cerdo mediante el modelo ARIMA, utilizando la serie de tiempo histórica para entrenar el modelo y medir la eficacia de los resultados con base en la estimación del error medio cuadrático (MSE). Aunque los resultados no son satisfactorios se establece una hoja de ruta para el modelado de series de tiempo.

Adicionalmente, Molina et al. (2017), propone capturar la estacionalidad de los precios del cerdo, con frecuencia anual, mediante un derivado del modelo ARIMA (X-12 ARIMA) con el objetivo de modelar y pronosticar los precios de forma efectiva. El objetivo de este estudio es determinar el punto óptimo de producción garantizando el mayor retorno posible. Para el análisis de la respuesta de la oferta en el mercado porcícola y el análisis de la volatilidad del precio en el mercado griego, Rezitis y Stavropoulos (2009) consideraron el modelo GARCH para estimar el precio esperado y su respectiva volatilidad. En el caso del precio, lograron pronosticar con un error de raíz cuadrada

medio (RMSE) inferior al 5%. En cuanto a la volatilidad del precio, lograron pronosticar con un RMSE inferior al 1%.

Es importante resaltar que en Colombia, el precio por kilogramo del cerdo es afectado por diversos factores como el precio del maíz, la soya y los concentrados. Siguiendo la cadena de estos factores, se puede observar que el clima es un factor que afecta en general el precio de los productos agrícolas (Asociación PorkColombia, 2022). La implementación de modelos como ARIMA y SARIMA en variables meteorológicas permite un análisis claro del comportamiento futuro de la misma. Es el caso de la implementación de estos modelos para el pronóstico de la temperatura en Nigeria y el análisis de desempeño por medio de métricas como RMSE Y MAPE (Kajuru, J et al., 2019).

También de Etienne et al., (2023), modela el precio del maíz, utilizando modelos ARMA. Los autores encuentran que es posible modelar la serie de tiempo con un error significativamente inferior a 1\$/fanega, siendo la fanega una unidad volumétrica usada en el comercio de granos; y logran gestionar el riesgo de manera efectiva optimizando la asignación de recursos y mejorando la eficiencia de este mercado.

Otros autores también han modelado y pronosticado series de tiempo de commodities como es el caso de los precios de las maderas como pino, abeto, haya, abedul y aliso; y el índice CCI de Polonia. Para el pronóstico de estas series de tiempo han propuesto el uso de los modelos ARIMA, SARIMA Y SARIMAX en busca del mejor ajuste de los datos a las series originales. Estos dos últimos modelos han tenido un mayor ajuste y menores errores de pronóstico debido al comportamiento estacional de la serie y a la influencia de variables exógenas (Banaś & Utnik-Banaś, 2021).

Existen investigaciones con propuestas más complejas para la modelación de la varianza como machine learning o modificaciones y combinaciones a modelos previamente planteados, pero siempre tomando como punto de partida el modelo ARIMA y GARCH, para el pronóstico de precios diarios de commodities agrícolas ( Zeng et al., 2023). El pronóstico por medio de redes neuronales de cosechas de trigo, avena, arroz, soja y maíz en Estados Unidos (Cheung et al., 2023) , el pronóstico de la demanda máxima de electricidad a nivel nacional para el mercado coreano (Lee & Cho, 2022) y el pronóstico

del precio de la electricidad europeo (Weron, 2014). Es también el caso del estudio de los mercados agrícolas en China, donde por medio de un modelo de pronóstico de redes neuronales, Xu y Zhang (2023), modelan los precios del aceite y se resalta la importancia de los modelos predictivos como herramientas de gestión del riesgo y de maximización de los rendimientos de las operaciones.

## Metodología y datos

La metodología Box-Jenkins, , está fundamentada en que los valores futuros de la variable están influenciados por los valores pasados, los cuales determinan patrones o tendencias (Box & Jenkins,1970). El modelo AR o autorregresivo (ver ecuación 1) se fundamenta en la idea de que el valor actual de la serie puede explicarse en función de  $p$  valores pasados.

Este modelo presenta la siguiente estructura:

Ecuación 1 Modelo AR

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t \quad (1)$$

Donde  $X_{t-1}$  es estadísticamente significativo para  $X_t$  y  $A_t$  es un proceso de ruido blanco.

El número de rezagos significativos para este modelo puede ser determinado mediante el gráfico de autocorrelación parcial, para el cual se determinará en que punto hay un cambio abrupto en el gráfico. Uno de los supuestos más importantes que deben cumplir las series de tiempo a trabajar a través de la metodología Box & Jenkins,(1970) , es ser estacionaria y en caso de no cumplirse esto, se requieren realizar diferenciaciones a la serie original para lograr que sea estacionaria. El modelo MA o de medias móviles (ver ecuación 2) se fundamenta en la idea de que el valor actual de la serie puede explicarse en función de  $q$  errores (residuales) pasados.

El modelo MA tiene la siguiente estructura:

Ecuación 2 Modelo MA

$$X_t = \mu + A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q} \quad (2)$$

Este parámetro puede ser determinado mediante el gráfico de autocorrelación, para el cual se determinará en que punto hay un cambio abrupto en el gráfico.

Finalmente, el modelo ARIMA tendrá la siguiente estructura:

Ecuación 3 Modelo ARIMA

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q} \quad (3)$$

El modelo SARIMA, es una extensión del modelo ARIMA que considera series de tiempo con patrones estacionales. Esta incluye 4 parámetros adicionales  $P$ ,  $D$ ,  $Q$  y  $n$ , en donde los primeros 3 están asociados a los componentes AR, I y MA de la parte estacional de la serie, en donde  $X_t$  se predice utilizando rezagos múltiples de la frecuencia estacional y el último está asociado a la frecuencia en la cual se presenta este patrón repetitivo que se espera modelar.

Las metodologías propuestas para determinar la precisión del modelo son la Raíz del Cuadrado Medio del Error, por sus siglas en inglés RMSE (ver ecuación 4), el cual indica que tan lejos se encuentran los datos pronosticados frente a los valores reales y el Error Porcentual Absoluto medio, por sus siglas en inglés MAPE (ver ecuación 5), el cual indica el porcentaje de error promedio del pronóstico frente al valor real.

Estos tienen la siguiente estructura:

Ecuación 4 Error RMSE

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (4)$$

Ecuación 5 Error MAPE

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (5)$$

Donde  $y_t$  es el valor real del precio por kilogramo y  $\hat{y}_t$  es el valor pronosticado a partir del modelo estadístico propuesto. Con base en lo anterior, a través de herramientas de software Python y la información del precio por kilogramo del cerdo obtenido de PorkColombia, se espera implementar un análisis estadístico para modelar y pronosticar el precio por

kilogramo del cerdo. Un modelo ARIMA es considerado ajustado si sus residuos tienen una distribución normal, no están autocorrelacionados y cuentan con varianza constante. En caso de que los residuos del modelo no cumplan las primeras dos condiciones, no se consideran ruido blanco y es necesario la búsqueda de un nuevo modelo. En caso de que no se cumpla la tercera condición, se debe implementar la modelación GARCH para modelar dicho residuo heterocedástico.

En la búsqueda del modelo óptimo, se plantea también la metodología de Refit. Esta metodología consiste en dividir el rango que se desea pronosticar en grupos de datos más pequeños, se realiza el pronóstico de la primera parte en la que se dividió el rango y este es incluido en el modelo. Posteriormente, se recalcula el modelo con el nuevo set de datos (suma de serie original y el pronosticado) y se pronostica el siguiente grupo de datos hasta llegar al rango deseado (Wang,X et al.,2023). Esta metodología es posible gracias a los recursos computacionales debido a que en cada proceso iterativo los coeficientes del modelo pueden cambiar y el resultado obtenido puede entregar valores más precisos.

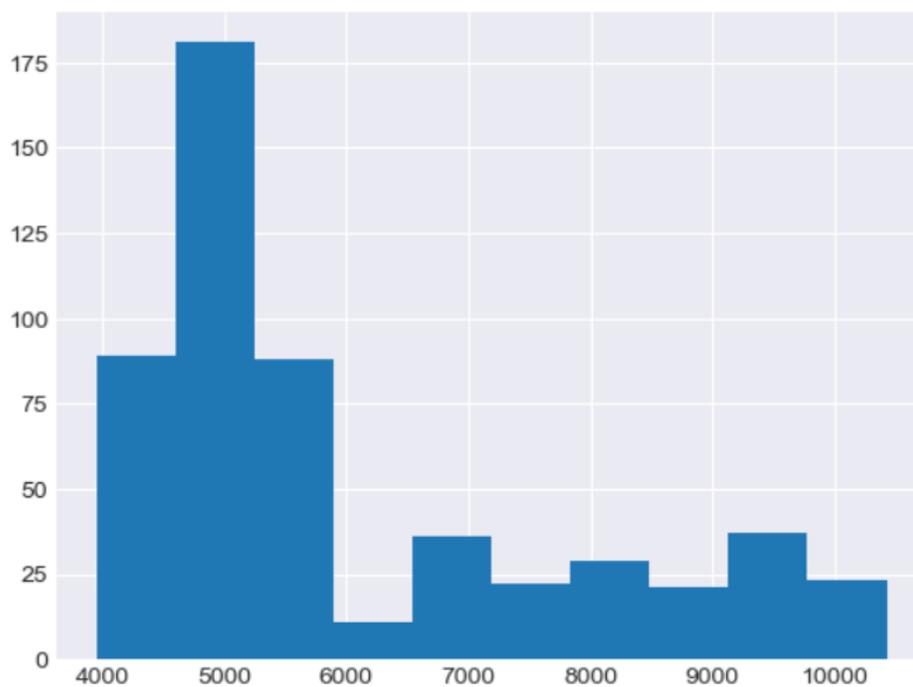
### **Datos**

La serie de tiempo a analizar se construye por medio de los precios semanales por kilogramo (COP/kg) del cerdo en pie, presentes en los boletines de PorkColombia desde el 13 de octubre de 2013 hasta el 21 de enero de 2024. Es importante detallar que este análisis se puede hacer para el promedio nacional o las otras regiones con mayor producción porcícola: Eje cafetero, Cundinamarca, Valle del Cauca y Meta. También se podrá realizar con los precios del cerdo en canal, y dependerá de la ubicación del productor o la parte de la cadena productiva en la que se encuentre el interesado. El primer paso para la aplicación de modelos de pronóstico es la preparación de los datos para identificar y eliminar outliers, los cuales corresponden a datos inusuales que no se comportan de acuerdo con los patrones generales de la información a estudiar. En este caso, se consideraran los métodos estadísticos de eliminación de datos atípicos como metodología propuestos por Alimohammadi y Chen, (2022).

## Estadísticas Descriptivas

Al analizar el histograma de la serie, se observa una serie con cola hacia la derecha. En este caso, corresponden a precios de mercado en periodos posteriores a la crisis del Covid-19 . La asimetría de los datos implica un reto adicional para modelar la serie utilizando modelos ARIMA. En la Figura 1 se muestra el histograma de la serie:

*Figura 1 Histograma de la serie*



Fuente: Elaborada por el autor.

En la Tabla 1, se presenta un análisis descriptivo de la serie de tiempo. En esta se evidencia que el valor de la media es afectado por la cola derecha entregando un valor superior al rango de mayor concentración de datos. Adicionalmente se observa una dispersión significativa de los datos, encontrando una desviación estándar superior a los 1,000 COP/kg

Tabla 1 Análisis descriptivo de la serie

Número de observaciones	537
Media	6,068.21
Desviación estándar	1,785.5
Mínimo	3,950
25%	4,866
50%	5,230
75%	7,155
Máximo	10,428

Se detallan estadísticas del precio por kilogramo del cerdo (media, desviación estándar, valor mínimo, cuartiles, valor máximo).

Fuente: Elaborada por el autor.

## Resultados

Al analizar los datos semanales, se encuentran datos faltantes en las últimas semanas de diciembre, asociadas a las festividades navideñas. La metodología propuesta para el llenado de estos datos faltantes es el reemplazo por el valor anterior (Velasco-Gallego & Lazakis,2022). En la Figura 2, se presenta el histórico de la variable de análisis:

Figura 2 Datos históricos del precio por kilogramo



Información histórica desde el 13 de octubre de 2013 hasta el 21 de enero de 2024.

Fuente: Elaborada por el autor.

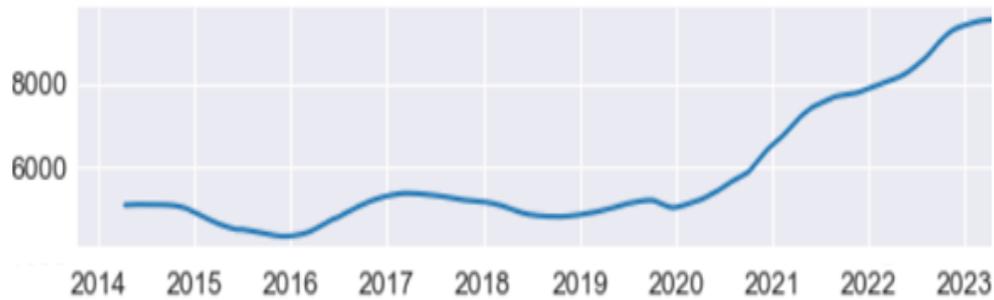
Para lograr determinar un modelo correcto, se deben analizar las componentes de una serie de tiempo:

- 1) **Tendencia:** permite analizar si en el tiempo la serie presenta cambios en la media. El análisis de esta componente permite determinar si la serie es estacionaria o no. De forma estadística se puede analizar la estacionariedad de la serie. Esto se logra con la Prueba de Dickey Fuller Aumentada, en la cual se establece a la siguiente hipótesis nula (Fuller, 1976):  
 $H_0$ : Existe una raíz unitaria para la serie (serie no estacionaria).

Para el caso de estudio, la Prueba de Dickey Fuller aumentada presenta un p-value de 0.758, indicando que la serie es no estacionaria.

Esto también se puede determinar con un gráfico de tendencia en la Figura 3:

*Figura 3 Tendencia de la serie*



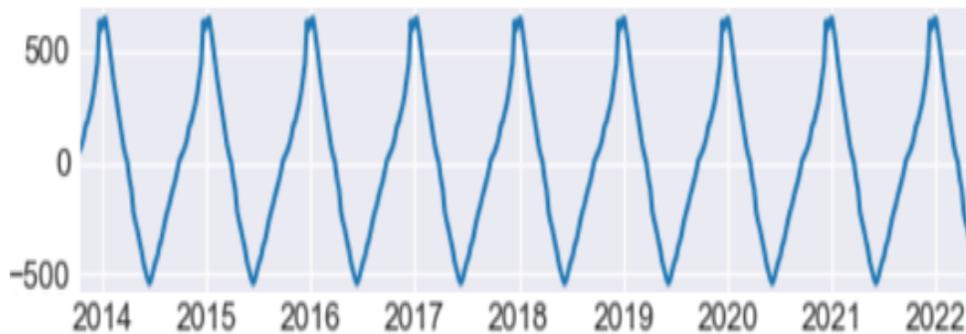
Describe la tendencia en el periodo de estudio de la serie.

Fuente: Elaborada por el autor.

Para lograr modelar la serie mediante el modelo ARIMA, la serie debe ser estacionaria por lo que se diferencia trabajando de este modo con los retornos. Se rechaza la hipótesis comprobando que la serie es estacionaria.

- 2) Estacionalidad: Esta componente permite determinar si existe un patrón o comportamiento repetitivo a lo largo del tiempo. Esta componente se asocia directamente con el modelo SARIMA. En la Figura 4 se presenta el gráfico de estacionalidad:

Figura 4 Estacionalidad de la serie.

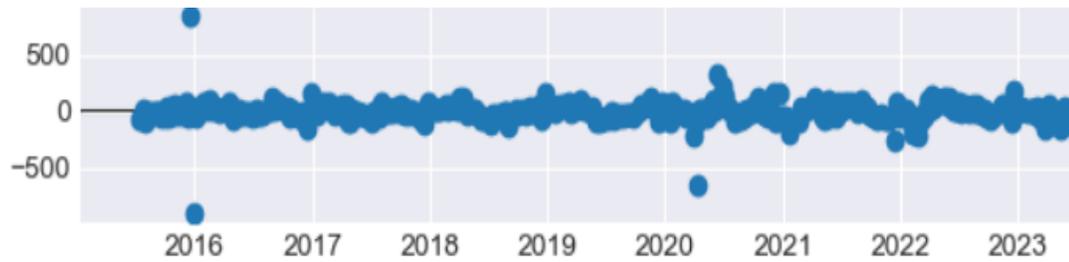


Se muestra la estacionalidad de la serie del precio por kilogramo del cerdo para periodos semanales.

Fuente: Elaborada por el autor.

- 3) En la Figura 3 se puede observar un comportamiento repetitivo cada año. Debido a que la variable de estudio es semanal se puede decir también que tiene un comportamiento repetitivo cada 52 semanas. En el análisis gráfico que se hace de la serie con base en el análisis de estacionalidad y la serie original, se observa que los datos anteriores al 2015, presentan un comportamiento atípico ya que no presentan puntos de inflexión como en los años siguientes. Debido a este comportamiento, se eliminará este grupo de datos con el objetivo de reducir el ruido en el modelo y encontrar un modelo ajustado. La eliminación de estos datos da como resultado una serie de tiempo con 473 valores.
- 4) Residuales: Esta componente está asociada a la parte aleatoria de la serie. Es decir, a lo que no se puede representar en la serie como estacionariedad, estacionalidad o ciclicidad. Al ser una componente aleatoria, no presentan patrón alguno y presentan una distribución normal de media cero, esta componente también es llamada ruido blanco o choques aleatorios. Para el caso de la serie diferenciada, se puede observar en la Figura 5 que estos valores son muy pequeños, favoreciendo el análisis de la serie por medio de la metodología estadística propuesta.

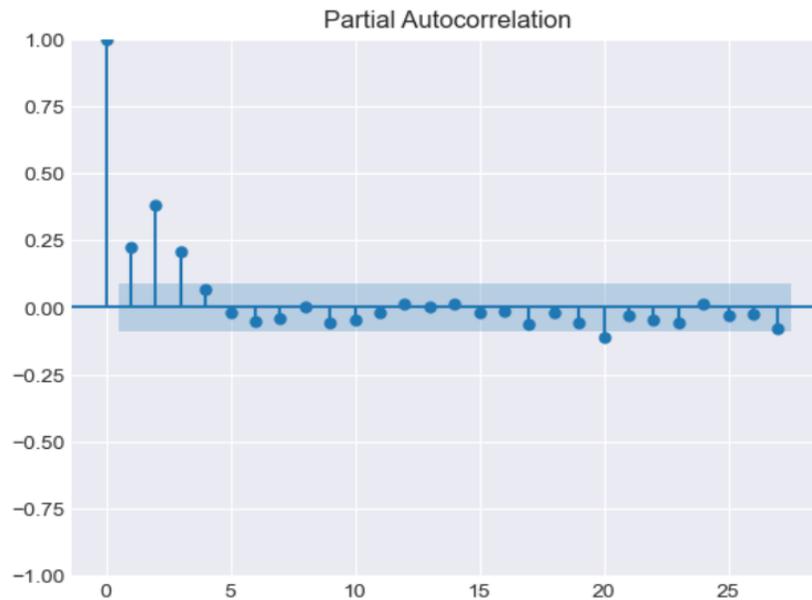
Figura 5 Residuales de la serie de tiempo diferenciada una vez.



Fuente: Elaborada por el autor.

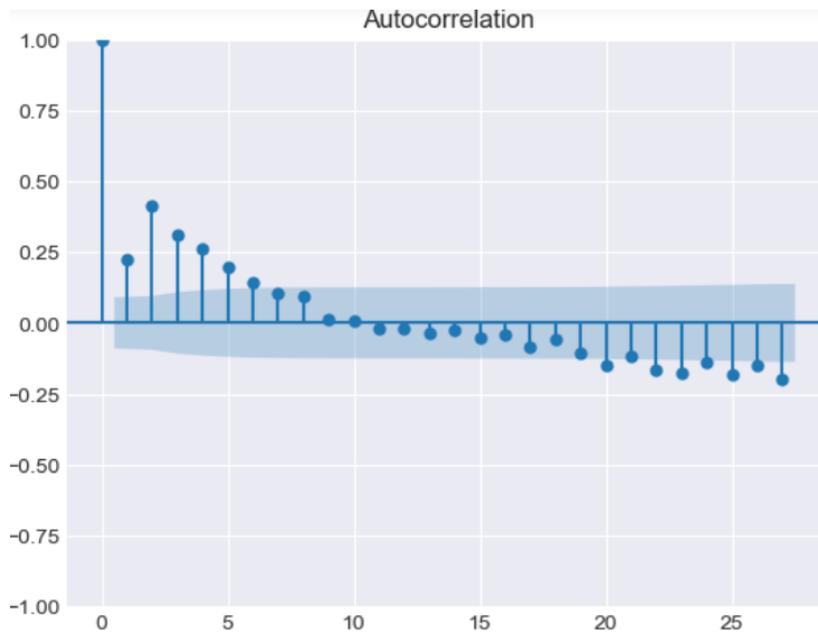
Con base en el análisis de estacionariedad y la prueba de Dickey Fuller Aumentada, se puede definir el valor  $d$  del modelo ARIMA como 1. Para determinar las componentes  $p$  y  $q$  del modelo ARIMA se utilizarán las funciones de autocorrelación y autocorrelación parcial. En la Figura 6 y en la Figura 7 se presentan ambos gráficos para la serie diferenciada:

Figura 6 Gráfico de autocorrelación parcial de la serie diferenciada.



Fuente: Elaborada por el autor.

Figura 7 Gráfico de autocorrelación de la serie diferenciada.



Fuente: Elaborada por el autor.

Con base en la información que presentan ambos gráficos se puede definir el valor de  $p$  y  $q$  como 1. Sin embargo, se propone la implementación de modelos adicionales con el objetivo de comparar los resultados en el pronóstico. Con base en lo anterior, se proponen los modelos ARIMA(1,1,1), ARIMA(2,1,1), ARIMA(2,1,2), ARIMA(1,1,2).

Las metodologías propuestas en la literatura para el modelo y pronóstico de series de tiempo, consiste en dividir la serie de tiempo en dos partes. La primera parte que se llamará train (entrenamiento), consiste en la porción de la serie mediante la cual el modelo determinará los coeficientes. La segunda parte se llamará test (prueba) y consiste en la porción con la cual se espera probar el modelo. Allí se comparará el pronóstico entregado por el modelo y los valores reales. Como se definió inicialmente, el objetivo de este estudio es realizar el pronóstico de la serie de tiempo para una ventana de 20 periodos, dando como resultado una serie train de 448 valores y una serie test de 20 valores. En la Figura 8 se muestra la división de la serie entre train y test:

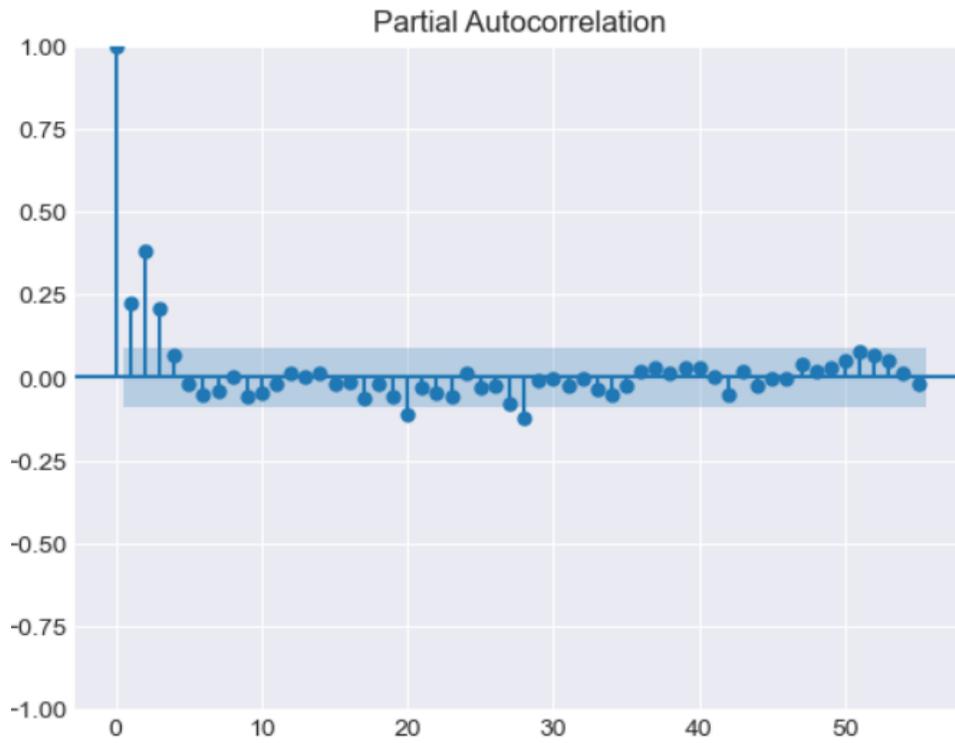
Figura 8 Gráfico de división de la serie entre train y test.



Fuente: Desarrollada por el autor

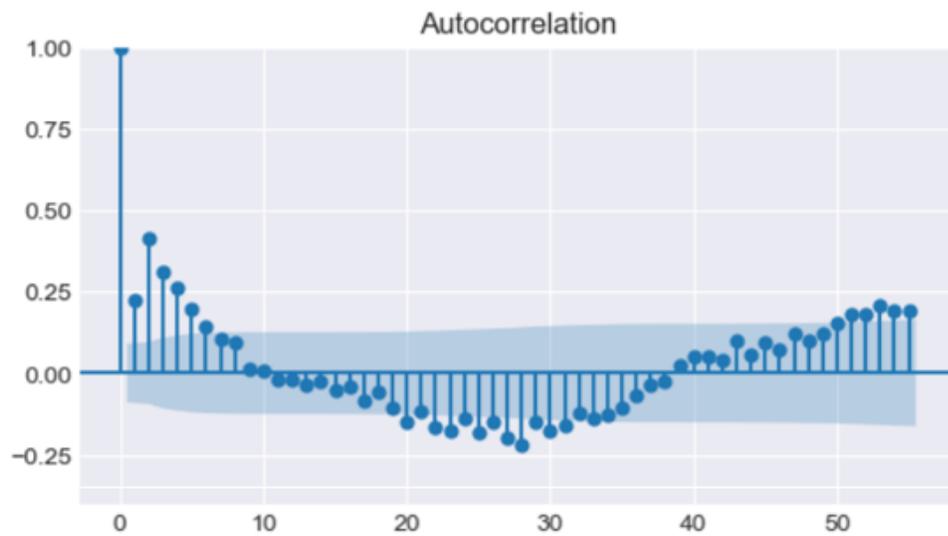
En el análisis de las componentes se evidenció la estacionalidad cada 52 semanas de la serie (estacionalidad anual), es porque se propone el enfoque del modelo SARIMA en busca de un mejor resultado. La selección de los parámetros  $P$  y  $Q$  se realiza mediante el análisis de las componentes estacionales de las funciones de autocorrelación parcial y autocorrelación. En la Figura 9 y la Figura 10 se presentan ambos gráficos:

Figura 9 Gráfico PACF para componentes estacionales de la serie.



Fuente: Elaborada por el autor.

Figura 10 Gráfico ACF para componentes estacionales de la serie.



Fuente: Elaborada por el autor.

Con base en el análisis gráfico se propone un valor de 1 para  $P$  y para  $Q$ , y para el caso de  $D$ , se propone asignar el valor de 0 debido a que la estacionalidad se observa en la serie original. Con base en el proceso iterativo y de optimización descrito anteriormente, se proponen los modelos SARIMA (2,1,1) (1,0,0)<sub>52</sub>, SARIMA (2,1,1) (1,0,1)<sub>52</sub>, SARIMA (2,1,1) (2,0,1)<sub>52</sub>. En la Tabla 2 se presenta el cuadro comparativo de los modelos:

*Tabla 2 Comparación de los modelos ARIMA y SARIMA propuestos.*

<b>MODELO</b>	<b>MSE (COP/kg)</b>	<b>MAPE (%)</b>
ARIMA (1,1,1)	48.82	0.39
ARIMA (2,1,1)	75.61	0.57
ARIMA (1,1,2)	110.98	0.90
ARIMA (2,1,2)	110.57	0.90
SARIMA (1,1,1)(1,0,0) <sub>52</sub>	41.71	0.38
SARIMA (1,1,1)(1,0,1) <sub>52</sub>	113.90	0.98
SARIMA (1,1,1)(2,0,1) <sub>52</sub>	89.90	0.76

Comparación de los modelos ARIMA y SARIMA propuestos para ajustar la serie de precio por kilogramo del cerdo..

Fuente: Elaborada por el autor.

Si bien todos los resultados presentan unas métricas de error inferiores al 1% y demuestran un ajuste significativo a la serie de datos real, el modelo con los mejores resultados es el SARIMA(1,1,1)(1,0,0)<sub>52</sub>. Este modelo se selecciona como el ideal para realizar pronósticos del precio por kilogramo del cerdo con el objetivo de tomar decisiones informadas.

En la Figura 11 y Figura 12 se presenta el pronóstico de modelo ARIMA(1,1,1) se presentan las gráficas de los modelos ARIMA y SARIMA con mejores resultados:

Figura 11 Gráfico de pronóstico de modelo  $ARIMA(1,1,1)$ .



Fuente: Elaborado por el autor.

Figura 12 Gráfico de pronóstico del modelo  $SARIMA(2,1,1)(1,0,0)_{52}$ .



Fuente: Elaborado por el autor

Para el caso de la serie de tiempo del precio del cerdo en el mercado porcícola, la implementación de la metodología refit no entrega mejoras en el pronóstico y por eso se descarta como herramienta de aproximación para análisis de datos futuros. Sin embargo, se resalta como herramienta a probar en busca del modelo con mejor ajuste para los datos.

### **Prueba de Robustez: Análisis de escenarios**

Aunque los resultados obtenidos son satisfactorios, es necesario analizar la ventana de tiempo de la sección pronosticada. Esta pertenece a un periodo de tiempo en el cual los datos tienen una tendencia al alza. Para profundizar en el análisis del modelo, se propone examinar su comportamiento en diferentes puntos de la serie, donde puedan presentarse eventos de cambio de tendencia en el mercado de interés y pueden ofrecer información valiosa sobre la precisión y robustez del modelo en diferentes condiciones. El análisis de escenarios es una herramienta fundamental al estudiar series de tiempo, pues con el paso de las semanas esta puede presentar múltiples cambios significativos que pueden afectar la toma de decisiones en los mercados. Estos cambios abruptos tienen algunas explicaciones:

- Estacionalidad: Como se planteó anteriormente, las componentes estacionales en la serie son comportamientos comunes, asociados a los ciclos reproductivos de los cerdos, en donde puede incrementar o disminuir significativamente la existencia de los cerdos en el mercado, afectando la oferta y la demanda de estos (Molina et al., 2017)
- Factores climáticos: un cambio abrupto en las condiciones climáticas puede generar sequías o inundaciones que afecten los insumos principales para la producción porcícola y a su vez encarecer estos, incrementando en consecuencia los precios del cerdo (Mirzabaev & Tsegai, 2012).
- Cambios en comportamientos de la demanda: Cambios en la oferta y la demanda en el mercado porcícola generan cambios en los precios del mismo (Pang et al., 2023). Debido a la existencia de bienes sustitutos como la carne de res, pollo, pescado y huevo, es probable que, ante la disminución en el precio de los otros bienes, incremente su demanda y genere en el mercado porcícola una caída drástica en la misma. Adicionalmente factores culturales y religiosos pueden promover consumo de determinados bienes en algunas festividades durante el año.

Para el análisis de escenarios se proponen los siguientes:

1. Concavidad: Caída de los precios y cambio negativo en la tendencia.
2. Convexidad: Alza de los precios y cambio positivo en la tendencia.

Si bien el modelo definido en los resultados fue el SARIMA(1,1,1)(1,0,0)<sub>52</sub>, en los escenarios propuestos este modelo presenta errores significativos en la presencia de cambios en la tendencia de la serie. El modelo con mejor ajuste en los tres escenarios es el modelo SARIMA(2,1,1)(2,1,1)<sub>52</sub>. Si bien este modelo incrementa el error en el escenario inicial, permite mantener este error más pequeño en los escenarios propuestos. En la Tabla 3 *Métricas para el escenario base* se presenta el error del modelo SARIMA(2,1,1)(2,1,1)<sub>52</sub> en el escenario base:

*Tabla 3 Métricas para el escenario base.*

<b>MODELO</b>	<b>MSE (COP/kg)</b>	<b>MAPE (%)</b>
SARIMA(2,1,1)(2,1,2) <sub>52</sub>	404.7	3.41

Fuente: Elaborada por el autor.

- 1) Escenario 1 -Concavidad: Para el análisis del punto de concavidad, se usará como test el periodo que comprende desde el 4 de diciembre de 2022 hasta el 21 de mayo de 2023. En la
- 2)
- 3)
- 4) *Figura 13* se presenta la división de la serie entre train y test.

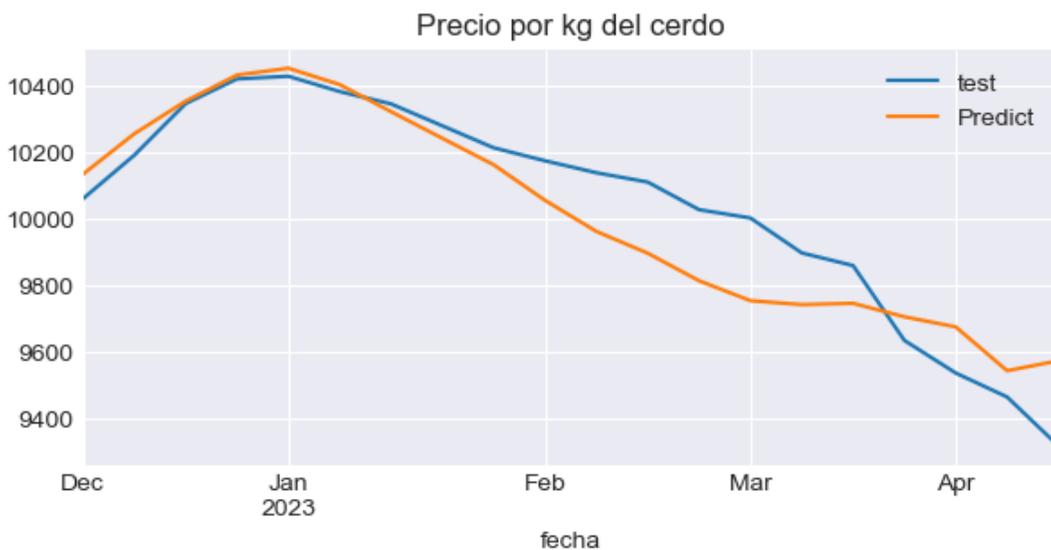
Figura 13 Gráfico de escenario de concavidad.



Fuente: Elaborada por el autor.

Una vez seleccionando el nuevo grupo de datos para el entrenamiento y para la prueba del modelo, se realiza nuevamente el ajuste del modelo previamente planteado, generando los resultados de la Figura 14:

Figura 14 Gráfico de pronóstico en escenario de concavidad.



Fuente: Elaborada por el autor.

Para el caso en donde luego de un incremento en los precios del cerdo se presenta una caída y cambio de tendencia en la serie, el modelo es capaz de capturar el cambio de tendencia de la variable con un incremento en el error en el largo plazo. Aunque se presenta el aumento del margen de error, el modelo permite entender la dinámica de la variable en condiciones periódicas. En la Tabla 4 se presentan las métricas usadas para determinar la calidad del pronóstico:

*Tabla 4 Métricas para el escenario de concavidad.*

<b>MODELO</b>	<b>MSE (COP/kg)</b>	<b>MAPE (%)</b>
SARIMA(2,1,1)(2,1,2) <sub>52</sub>	131.65	1.06

Fuente: Elaborada por el autor.

- 5) Escenario 2- Convexidad: Para el análisis del punto de concavidad, se usará como test el periodo que comprende desde el 23 de abril de 2023 hasta el 3 de septiembre de 2023. En la Figura 15 .

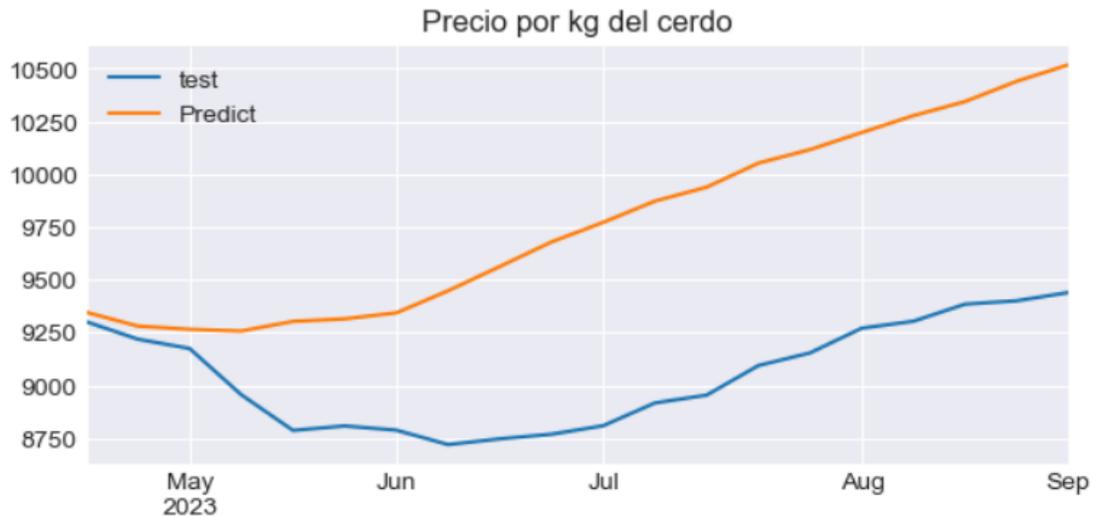
*Figura 15 Gráfico de escenario de convexidad.*



Fuente: Elaborada por el autor.

Una vez actualizados los grupos de datos nuevamente, se buscará el ajuste del modelo con los parámetros definidos. El resultado se presenta en la Figura 16.

Figura 16 Gráfico de pronóstico en escenario de convexidad.



Fuente: Elaborada por el autor.

Para el caso en el que luego de una caída en los precios del cerdo, se presenta un cambio de tendencia hacia el alza, el modelo presenta un error alto y una imprecisión en este. Esto puede generar diferencias significativas a la hora de tomar decisiones cruciales en el mercado porcícola. En la Tabla 5 se presentan las métricas usadas para determinar la calidad del pronóstico.

*Tabla 5 Métricas para el escenario de convexidad.*

<b>MODELO</b>	<b>MSE (COP/kg)</b>	<b>MAPE (%)</b>
SARIMA(2,1,1)(1,0,0) <sub>52</sub>	793.47	7.92

Fuente: Elaborada por el autor.

### **Recomendaciones en la Gestión de riesgo del mercado porcícola a partir de la modelación del precio por kg/COP de la carne**

Como se definió anteriormente, el primer objetivo consistía en modelar y pronosticar la serie del precio por kilogramo del cerdo en pie para el departamento de Antioquia. Este objetivo se logra mediante las evidencias propuestas con una brecha significativa en el escenario de punto de inflexión convexo. Una vez obtenido este modelo, el objetivo siguiente de este estudio es definir estrategias para gestionar los riesgos en este mercado.

Entendiendo el futuro comportamiento de la variable de estudio, es posible tomar decisiones de forma oportuna con el objetivo de maximizar los retornos de la operación (Vilca et al.,2023).Con base en esto, la primera metodología propuesta para la gestión de riesgo está orientada a una óptima programación y planeación de la producción de los lotes porcícolas para que las 20 semanas planteadas como periodo de ceba finalicen en este punto máximo y asimismo se puedan vender los lotes de cerdos al mejor precio posible.

Partiendo de que las transacciones en el mercado porcícola colombiano consisten en contratos basados en los precios presentados por la asociación PorkColombia, entender y estimar los precios futuros puede favorecer al productor al establecer mejores condiciones contractuales, entendiendo los márgenes de error que puede presentar el modelo. De este modo se puede buscar definir precios en los contratos comerciales buscando ganarle al mercado sin necesidad de esperar los boletines de precios de PorkColombia. Además, estimar el precio de la variable al momento de la venta, le permite al productor organizar su estructura de costos, en caso de que el escenario tenga una tendencia a la baja para buscar la mitigación de las pérdidas.

Entendiendo las dinámicas durante todo el año del mercado porcícola y los escenarios de precios mínimos, se propone también una diversificación de la producción y de los mercados. Una herramienta fundamental para la gestión de riesgos es la diversificación de las inversiones, llamada en los mercados financieros portafolios diversificados. Entendiendo la dinámica de los mercados, se plantea el diseño de un portafolio con productos como ganado bovino y productos agrícolas cuyos tiempos de ceba o cosecha coincidan con los niveles mínimos de las demás inversiones, logrando así maximizar los rendimientos y buscar ingresos constantes. Esta diversificación de mercados disminuye el impacto en las caídas drásticas de precios (Silvestri, et al., 2020).

Una vez establecido el portafolio con las opciones previamente propuestas, una correcta administración de inventarios ayuda a tener una oportuna gestión del riesgo y permite maximizar los rendimientos, manteniendo una liquidez óptima (Baker, et al., 2024). Esto quiere decir que el productor podrá buscar tener la mayor cantidad de productos que tengan mejor precio en el mercado y en consecuencia una menor cantidad de productos cuyo precio este en puntos ineficientes para vender.

En caso de que mediante el pronóstico de precios se observe una ventana ineficiente o negativa para el productor (caída de precios), se puede realizar una gestión de caja preventiva con el objetivo de evitar el riesgo de liquidez ( Tang & Wang, 2022) y cumplir todas las responsabilidades operativas y financieras de la empresa. Al considerar estas áreas para la gestión del riesgo en el mercado porcícola se establece una metodología robusta para la mitigación de riesgos y aprovechamiento de oportunidades de mercado.

## Conclusiones

El pronóstico de series de tiempo es una herramienta fundamental en la gestión de riesgos debido a que mediante esta es posible anticiparse a eventos en un mercado específico y tomar decisiones con la mejor información disponible en búsqueda de maximizar los rendimientos o mitigar los riesgos asociados a la operación del mercado de estudio. Con esta información, las compañías pueden prepararse para cambios drásticos en el mercado. Esta gestión de riesgo facilita el ajuste de estrategias comerciales, productivas, de inventario y planeación de forma óptima, contribuyendo a una gestión eficiente y con mejores rentabilidades. La implementación de estas herramientas se traduce en una mejor posición en el mercado frente a la competencia, que puede promover resultados favorables.

En esta investigación se analizó comportamiento del precio por kilogramo del cerdo en Antioquia mediante la implementación de modelos estadísticos avanzados. Modelos como ARIMA y SARIMA), permiten modelar las series de tiempo previendo fluctuaciones. Estos modelos, si bien ofrecen una metodología robusta, también ofrecen una herramienta asequible para cualquier persona interesada, como investigadores, productores, analistas, etc. Mediante los modelos previamente mencionados, es posible modelar la serie de tiempo del kilogramo del cerdo en Antioquia, logrando resultados precisos mediante la captura de tendencias en el largo plazo y condiciones estacionales y cíclicas. Es importante realizar un análisis de escenarios al modelar una serie de tiempo debido a que el rango de prueba que se realice en primera instancia puede presentar una tendencia definida y puede sesgar la calificación del modelo. En estos escenarios es importante incluir puntos de inflexión tanto cóncavos como convexos con el objetivo de lograr medir y probar los posibles sucesos a lo largo del tiempo en la variable de estudio.

Los modelos que mejor se ajustan a la serie del precio por kilogramo del cerdo son SARIMA(2,1,1)(1,0,0)<sub>52</sub> y SARIMA(2,1,1)(1,0,0)<sub>52</sub> con un incremento significativo en el error cuando hay un cambio abrupto en la serie. Herramientas computacionales como el refitting pueden ser de utilidad en modelos de pronóstico donde no es necesario mantener los coeficientes constantes, buscando acotar más la brecha entre los valores reales y pronosticados, logrando resultados más ajustados de la serie de datos.

La gestión de riesgos es un tema que cada vez tiene más relevancia en los mercados y es importante implementar acciones que permitan a las empresas tomar decisiones informadas con un horizonte de tiempo significativo con el objetivo de anticiparse a los hechos y evitar situaciones negativas en las mismas. Este trabajo contribuye a la sensibilización en Colombia sobre la importancia de realizar una gestión de riesgo oportuna y con herramientas como la propuesta se facilita la toma de decisiones en busca de mejores resultados financieros en una empresa. Si bien este estudio está enfocado en el sector porcícola, esta metodología se puede incorporar en cualquier sector de la economía colombiana.

## Recomendaciones

Es importante resaltar que el modelo que mejor se ajusta en escenarios con cambios drásticos en la serie, como puntos de inflexión que pueden estar asociados a factores económicos, climáticos, entre otros, presenta un error significativo en la precisión del modelo. La facilidad de estos modelos para acoplarse a estos cambios súbitos es fundamental para lograr estimaciones cercanas a realidad y a su vez decisiones óptimas y con resultados eficientes.

En busca de un mejor resultado, se puede considerar la inclusión de variables exógenas para la implementación de un modelo SARIMAX, el cual amplía la capacidad del modelo para predecir y capturar efectos externos que afectan la serie de tiempo de interés. Las variables, como bienes sustitutos o insumos para la producción de la actividad a estudiar, ofrecen una visión mas completa de los factores que más pueden influenciar determinado resultado. Estas variables, permiten lograr resultados mas precisos y acotados con la realidad facilitando el análisis de resultados. Para el mercado porcícola se proponen variables como el precio por kilogramo de la res, bien sustituto de la variable, el precio del maíz y de la soya, materias primas fundamentales para la ceba de los cerdos. Si bien el inconveniente que se materializa en este modelo es el desconocimiento del comportamiento de las variables exógenas, puede ser muy útil para realizar un análisis de escenarios por medio de la experiencia y contexto del productor, el cual dada la experiencia puede hacer suposiciones sobre estas variables. Existen múltiples aproximaciones para el pronóstico de series de tiempo que pueden ser consideradas en complemento o reemplazo de los modelos ARIMA. Es el caso del pronóstico de la varianza por medio de modelos GARCH, en los cuales, dadas unas condiciones de normalidad y heterocedasticidad en los residuos, se puede pronosticar la varianza o error del modelo para ajustar los resultados. Es también el caso de las componentes principales y múltiples métodos de Machine Learning como el Recurrent Neural Network (RNN) que permiten modelar series de tiempo.

Debido a la facilidad en la recopilación de los precios semanales del cerdo, se propone un reajuste al modelo en esta misma periodicidad, agregando datos reales a la serie y pronosticando con mayor precisión los datos futuros.

## Referencias

- [1] Ministerio de Agricultura y Desarrollo Rural. (2021). Cadena Cárnica Porcina. Consultado el 09 de Octubre de 2023, en:  
<https://sioc.minagricultura.gov.co/Porcina/Documentos/2021-06-30%20Cifras%20Sectoriales.pdf>
- [2] PorkColombia. (2022). Informe de Gestión Porkcolombia 2022. Consultado el 09 de Octubre de 2023, en: [https://porkcolombia.co/wp-content/uploads/2023/03/Informe-de-Gestion-Porkcolombia-2022-VF\\_compressed.pdf](https://porkcolombia.co/wp-content/uploads/2023/03/Informe-de-Gestion-Porkcolombia-2022-VF_compressed.pdf)
- [3] PorkColombia (2013-2023).Ronda de Precios. Consultado el 20 de Octubre de 2023, en : [Ronda de Precios – Porkcolombia](#)
- [4] Porcícola Líder de Colombia (nd).Razas. Consultado el 09 de Octubre de 2023, en : [Razas | Porcícola Líder de Colombia \(porcicolalider.com\)](#)
- [5] Minagricultura.(2013). Levante y ceba de cerdos: etapas de una industria en continuo crecimiento. Boletín mensual INSUMOS Y FACTORES ASOCIADOS A LA PRODUCCIÓN AGROPECUARIA,18. [insumos factores de produccion dic 2013.pdf \(agronet.gov.co\)](#)
- [6] Zeng,L, et al.( 2023). Optimal forecast combination based on PSO-CS approach for daily agricultural future prices forecasting. Applied Soft Computing,132. <https://doi.org/10.1016/j.asoc.2022.109833>
- [7] Lee,J & Cho,Y.(2022).National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model?.Energy.  
[8] <https://doi.org/10.1016/j.energy.2021.122366>
- [9] Banaś,J & & Utnik-Banaś,K.(2021).Evaluating a seasonal autoregressive moving average model with an exogenous variable for short-term timber price forecasting. Forest Policy and Economics,131. <https://doi.org/10.1016/j.forpol.2021.102564>
- [10] Weron,R.(2014).Electricity price forecasting: A review of the state-of-the-art with a look into the future. International Journal of Forecasting,30, 1030-1081. <https://doi.org/10.1016/j.ijforecast.2014.08.008>
- [11] Seyedhossein,S & Moeini-Aghtaie,M.(2022) Risk management framework of peer-to-peer electricity markets.Energy,261.

- <https://doi.org/10.1016/j.energy.2022.125264>
- [12] Choi,B &, Kim,S.(2018).Price volatility and risk management of oil and gas companies: Evidence from oil and gas project finance deals.Energy Economics,76,594-605.  
<https://doi.org/10.1016/j.eneco.2018.05.020>
- [13] H, Mo. (2019). Analysis on the Fluctuation of Pig Price in China.2019 6th International Conference on Information Science and Control Engineering (ICISCE),152-158,  
10.1109/ICISCE48695.2019.00040
- [14] Clemen,R.(1989). Combining forecasts: A review and annotated bibliography. International Journal of Forecasting,5,559-583. [https://doi.org/10.1016/0169-2070\(89\)90012-5](https://doi.org/10.1016/0169-2070(89)90012-5)
- [15] Myers,M. (1998). Ganaderia y cria de animales. ENCICLOPEDIA DE SALUD Y SEGURIDAD EN EL TRABAJO,70. <https://www.jmcprl.net/OIT%20Completa/70.pdf>
- [16] Alimohammadi,H & Chen,S.(2022). Performance evaluation of outlier detection techniques in production timeseries: A systematic review and meta-analysis. Expert Systems with Applications,191. <https://doi.org/10.1016/j.eswa.2021.116371>
- [17] Zielińska-Sitkiewicz,M & Chrzanowska,M.(2021). Prediction of Pork Meat Prices by Selected Methods as an Element Supporting the Decision-making Process. Operations Research and Decisions,3. <http://dx.doi.org/10.37190/ord210307>
- [18] Rezitis,A & Stavropoulos,K.(2015). Modeling Pork Supply Response and Price Volatility: The Case of Greece. Journal of Agricultural and Applied Economics,41,145-162.  
<https://doi.org/10.1017/S1074070800002601>
- [19] Box,G & Jenkins,G.(1970).Time series analysis: Forecasting and control.Holden-Day.
- [20] Fuller, WA (1976). [Introducción a las Series Temporales Estadísticas](#). Nueva York: John Wiley and Sons.
- [21] Kajuru, J et al.(2019). Forecasting Performance of ARIMA and Sarima Models on Monthly Average Temperature of Zaria, Nigeria. ATBU Journal of Science, Technology and Education, 7, 205-212.  
[https://www.researchgate.net/publication/336837496\\_Forecasting\\_Performance\\_of\\_Arima\\_and\\_Sarima\\_Models\\_on\\_Monthly\\_Average\\_Temperature\\_of\\_Zaria\\_Nigeria](https://www.researchgate.net/publication/336837496_Forecasting_Performance_of_Arima_and_Sarima_Models_on_Monthly_Average_Temperature_of_Zaria_Nigeria)
- [22] Wang,X et al.(2023). Distributed ARIMA models for ultra-long time series. International Journal of Forecasting,39,1184-1163.

- <https://doi.org/10.1016/j.ijforecast.2022.05.001>
- [23] Silvestri,L et al. (2020). System diversification and grazing management as resilience-enhancing agricultural practices: The case of crop-livestock integration. *Agricultural Systems*,184. <https://doi.org/10.1016/j.agsy.2020.102904>
- [24] Baker,S er al.(2024). Financial returns to household inventory management. *Journal of Financial Economics*,151. <https://doi.org/10.1016/j.jfineco.2023.103758>
- [25] Tang,T & Wang,Y.(2022). Liquidity Shocks, Price Volatilities, and Risk-managed Strategy: Evidence from Bitcoin and Beyond. *Journal of Multinational Financial Management*,64. <https://doi.org/10.1016/j.mulfin.2022.100729>
- [26] Etienne, X et al.(2023). Forecasting the U.S. season-average farm price of corn: Derivation of an alternative futures-based forecasting model. *Journal of Commodity Markets*.30.<https://doi.org/10.1016/j.jcomm.2023.100333>
- [27] Xu,X & Zhang,Y.(2023). Edible oil wholesale price forecasts via the neural network.*Energy Nexus*.12.<https://doi.org/10.1016/j.nexus.2023.100250>
- [28] Velasco-Gallego, C & Lazakis, I .(2022). Analysis of Variational Autoencoders for Imputing Missing Values from Sensor Data of Marine Systems. *Journal of Ship Research*.66,193-202. 10.5957/JOSR.09210032
- [29] Cheung,L et al.,(2023). Using a novel clustered 3D-CNN model for improving crop future price prediction. *Knowledge-Based Systems*.260. <https://doi.org/10.1016/j.knosys.2022.110133>
- [30] Wang, M (2019). Short-term forecast of pig price index on an agricultural internet platform. *Agribusiness*. doi:10.1002/agr.21607
- [31] Molina,I et al.,(2017). ANALYSIS OF SEASONALITY IN MONTHLY PORK PRICES IN THE PHILIPPINES BASED ON X-12 ARIMA. *J. ISSAAS*. 23,215-226.
- [32] Mirzabaev,A & Tsegai,D.(2012 ). Effects of Weather Shocks on Agricultural Commodity Prices in Central Asia. *ZEF - Discussion Papers on Development Policy*. 171. <https://doi.org/10.22004/ag.econ.140769>
- [33] Pang,J et al. (2023). Supply and Demand Changes, Pig Epidemic Shocks, and Pork Price Fluctuations: An Empirical Study Based on an SVAR Model. *Sustainability*.15. <https://doi.org/10.3390/su151713130>

