

UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE ESTADÍSTICA



TESIS

**Modelos Arima para pronosticar la producción de limón en el Perú
mediante la metodología de Box Jenkins Años 2010-2025**

Para optar por el Título Profesional de:

Licenciado en Estadística

Presentado por:

Bach. Tarrillo Hernández Ruth Mireyla

Bach. Vilchez Orlandini, Luz Alicia

Asesor:

Dr. Alfonso Tesén Arroyo

Lambayeque – Perú

2026



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FISICAS Y MATEMATICAS
UNIDAD DE INVESTIGACIÓN



TESIS

**Modelos Arima para pronosticar la producción de limón en el
Perú mediante la metodología de Box Jenkins Años 2010-2025**

Presentado por:

Bach. Tarrillo Hernández Ruth Mireyla


FIRMA

Bach. Vilchez Orlandini, Luz Alicia


FIRMA

Asesor:

Dr. Alfonso Tesén Arroyo


FIRMA



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FISICAS Y MATEMATICAS
UNIDAD DE INVESTIGACIÓN



TESIS

**Modelos Arima para pronosticar la producción de limón en el
Perú mediante la metodología de Box Jenkins Años 2010-2025**

Aprobado por:

Dr. Wilver Omero Rodríguez López
Presidente

Dr. Jorge Antonio Acosta Piscoya
Secretario

M.Sc. Manuel Francisco Hurtado Sánchez
Vocal

ACTA DE SUSTENTACIÓN

 UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DECANATO
Ciudad Universitaria - Lambayeque
LICENCIADA - RESOLUCIÓN DEL CONSEJO DIRECTIVO N° 015 - 2023-SUNEDU / CD

 0101


ACTA DE SUSTENTACIÓN N° 062.-2026.-D/FACFyM

Siendo las 12 m. del día 10 de Agosto del 2026, se reunieron los miembros del jurado evaluador de la Tesis titulada:
Modelos Arima para pronosticar la producción de limón en el Perú mediante la metodología de Box-Jenkins Años 2010-2025




Designados por Resolución N° 356-2025-D/FACFyM D/FACFyM de fecha 24 ABRIL 2025
Con la finalidad de evaluar y calificar la sustentación de la tesis antes mencionada, conformada por los siguientes docentes:

<u>Dr. Wilver Omero Rodríguez López</u>	Presidente
<u>Dr. Jorge Antonio Acosta Piscoya</u>	Secretario
<u>Msc. Manuel Francisco Hurtado Sánchez</u>	Vocal

La tesis fue asesorada por (el) (la) Dr. Alfonso Tesén Arroyo, nombrado por Resolución N° 356-2026 D/FACFyM de fecha 24 ABRIL 2025
El Acto de Sustentación fue autorizado por Resolución N° 555-2026 D/FACFyM de fecha 27 de Julio 2026

La Tesis fue presentada y sustentada por (el) (los) Bachiller (es): TARRILLO HERNANDEZ, RUTH MIRIELA Y VILCHEZ ORLANDINI LUZ ALICIA y tuvo una duración de 14:30 minutos.
Después de la sustentación, y absueltas las preguntas y observaciones de los miembros del jurado se procedió a la calificación respectiva, otorgándole el Calificativo de diecisiete (17) en la escala vigesimal, mención (BUENO).
Por lo que queda(n) apto(s) para obtener el Título Profesional de LICENCIADA EN ESTADISTICA de acuerdo con la Ley Universitaria 30220 y la normatividad vigente de la Facultad de Ciencias Físicas y Matemáticas y la Universidad Nacional Pedro Ruiz Gallo.

Siendo las 1:30 se dio por concluido el presente acto académico, dándose conformidad al presente acto con la firma de los miembros del jurado.

 <u>Dr. Wilver Omero Rodríguez López</u> Presidente	 <u>Dr. Acosta Piscoya, Jorge</u> Secretario
 <u>Msc. Manuel Hurtado Sánchez</u> Vocal	 <u>Dr. Alfonso Tesén Arroyo</u> Asesor

CONSTANCIA DE VERIFICACION DE ORIGINALIDAD

Yo, Dr. Alfonso Tesén Arroyo, Asesor de tesis de las estudiantes, Luz Alicia Vilchez Orlandini y Ruth Mireyla Tarrillo Hernández, del trabajo de investigación titulado “Modelos Arima para pronosticar la producción de limón en el Perú mediante la metodología de Box Jenkins Años 2010-2025”.

Luego de la revisión exhaustiva del documento constato que la misma tiene un índice de similitud de 14% verificable en el reporte de similitud del programa de Turnitin.

El suscrito analizó dicho reporte y concluyó que cada una de las coincidencias detectadas no constituyen plagio, a mi leal saber y entender la tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad Nacional Pedro Ruiz Gallo.

Lambayeque, 15 de Julio del 2026



FIRMA

Alfonso Tesén Arroyo

DNI:17578166

REPORTE DE TURINITIN

Modelos Arima para pronosticar la producción de limón en el Perú mediante la metodología de Box Jenkins Años 2010-2025

INFORME DE ORIGINALIDAD

14% INDICE DE SIMILITUD	13% FUENTES DE INTERNET	4% PUBLICACIONES	8% TRABAJOS DEL ESTUDIANTE
-----------------------------------	-----------------------------------	----------------------------	--------------------------------------

FUENTES PRIMARIAS

1	repositorio.unprg.edu.pe:8080 Fuente de Internet	3%
2	repositorio.unprg.edu.pe Fuente de Internet	2%
3	Submitted to Universidad Nacional de Piura Trabajo del estudiante	1%
4	Submitted to ITESM: Instituto Tecnologico y de Estudios Superiores de Monterrey Trabajo del estudiante	1%
5	Submitted to Universidad Nacional de Trujillo Trabajo del estudiante	<1%
6	www.scielo.org.bo Fuente de Internet	<1%
7	dokumen.pub Fuente de Internet	<1%
8	icc.org.gt Fuente de Internet	<1%
9	repositorio.unap.edu.pe Fuente de Internet	<1%
10	hdl.handle.net Fuente de Internet	<1%
11	Submitted to Universidad Nacional Federico Villarreal Trabajo del estudiante	<1%
12	Submitted to Universidad Nacional de Frontera Trabajo del estudiante	<1%
13	Amelia Reyes Martínez, Juan Carlos Castro Ramírez, Guillermo Martínez Atilano. "Transferencia y conservación de la infraestructura hidroagrícola en el Alto Río Lerma, Guanajuato", Entreciencias: Diálogos en la Sociedad del Conocimiento. 2019 Publicación	<1%


Alfonso Tesén Arroyo
DNI:17578166

14	Submitted to Universidad San Ignacio de Loyola Trabajo del estudiante	<1 %
15	Submitted to Universidad Autonoma De Guadalajara A.C. Trabajo del estudiante	<1 %
16	rstudio-pubs-static.s3.amazonaws.com Fuente de Internet	<1 %
17	ri.ues.edu.sv Fuente de Internet	<1 %
18	doczz.com.br Fuente de Internet	<1 %
19	burjcdigital.urjc.es Fuente de Internet	<1 %
20	Laurente Blanco, Luis Francisco. "Modelamiento econométrico de la inflación en el Perú, período 2000-2019", Universidad Nacional del Altiplano de Puno (Peru) Publicación	<1 %
21	Quispe Vargas, Walter. "Sieve Bootstrap en series de tiempo de nubosidad en el Caribe", Proquest, 20111108 Publicación	<1 %
22	tdx.cat Fuente de Internet	<1 %
23	rumoresdepehuajonoticias.blogspot.com Fuente de Internet	<1 %
24	www.geeksforgeeks.org Fuente de Internet	<1 %
25	www.edutecne.utn.edu.ar Fuente de Internet	<1 %
26	www.futurosyopciones.com Fuente de Internet	<1 %
27	Submitted to Universidad Estatal Amazonica- Trabajo del estudiante	<1 %
28	Submitted to Universidad Industrial de Santander UIS Trabajo del estudiante	<1 %
29	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	<1 %
30	repositorio.uptc.edu.co Fuente de Internet	<1 %



Alfonso Tesén Arroyo
DNI:17578166

31	Submitted to University of the Andes Trabajo del estudiante	<1 %
32	revistas.lasalle.edu.co Fuente de Internet	<1 %
33	Submitted to Universidad Carlos III de Madrid - EUR Trabajo del estudiante	<1 %
34	Submitted to Universidad de Málaga - Tii Trabajo del estudiante	<1 %
35	www.dspace.espol.edu.ec Fuente de Internet	<1 %
36	Submitted to Pontificia Universidad Catolica del Peru Trabajo del estudiante	<1 %
37	api-repositorio.unapiquitos.edu.pe Fuente de Internet	<1 %
38	repositorio.ucsm.edu.pe Fuente de Internet	<1 %
39	hal.science Fuente de Internet	<1 %
40	Submitted to Barcelona School of Management Trabajo del estudiante	<1 %
41	Patrícia S. Silva, Renata Libonati, Jose A. Marengo, Mabel Calim Costa, Lincoln Muniz Alves, Isabel Belloni Schmidt. "Chapter 13 Fire in the Anthropocene", Springer Science and Business Media LLC, 2025 Publicación	<1 %
42	Submitted to Universidad Americana Trabajo del estudiante	<1 %
43	repositorio.utn.edu.ec Fuente de Internet	<1 %

Excluir citas
Excluir bibliografía

Activo
Activo

Excluir coincidencias

< 15 words



Alfonso Tesén Arroyo

DNI:17578166

RECIBO DE TURNITIN



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por **Turnitin**. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Alicia_ruth Vilchez_tarrillo
Título del ejercicio: Quick Submit
Título de la entrega: Modelos Arima para pronosticar la producción de limón en el ...
Nombre del archivo: th_Mireyla_Vilchez_Orlandini_Luz_Alicia_-_2026_-_14.07.26.docx
Tamaño del archivo: 1.84M
Total páginas: 77
Total de palabras: 15,235
Total de caracteres: 84,267
Fecha de entrega: 17-jul-2026 09:34p. m. (UTC-0500)
Identificador de la entrega: 2999518447

UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA PROFESIONAL DE ESTADÍSTICA



TESIS

Modelos Arima para pronosticar la producción de limón en el Perú
mediante la metodología de Box Jenkins Año 2026-2027

Para optar por el Título Profesional de:
Licenciado en Estadística

Presentado por:
Duch, Tati Oriana Ruth Mireyla
Duch, Mirella Oriana Ruth Alicia

A cargo:
Dr. Alfonso Tesén Arroyo

Lambayeque - Perú
160

Alfonso Tesén Arroyo

DNI:17578166

AGRADECIMIENTO

Agradecemos a Dios por bendecirnos y darnos fuerzas para culminar esta etapa académica e impulsarnos a seguir adelante y a seguir creciendo como profesionales.

A nuestro asesor Dr. Alfonso Tesén Arroyo por su orientación, paciencia y valiosos conocimientos los cuales fueron esenciales para el desarrollo y culminación de nuestro proyecto de investigación. De manera especial agradecer a nuestros docentes que con sus valores y enseñanzas nos han formado para ser profesionales exitosos.

A la Universidad Nacional “Pedro Ruiz Gallo” por habernos cedido un lugar en sus aulas para estudiar y permitirnos tener una excelente formación profesional.

DEDICATORIA

En primer lugar, agradezco a Dios por haberme permitido llegar hasta este momento tan importante de mi vida

A mis padres y a mi hermana, por su amor y por motivarme siempre a no rendirme, Gracias por creer en mí y acompañarme en cada paso de este sueño.

En especial, a mi querido papá, Salvador, quien siempre confió en mí y me impulsó a seguir adelante. Aunque hoy ya no esté físicamente a mi lado, su amor y su recuerdo viven en mi corazón y me acompañan espiritualmente en cada uno de mis logros. Este logro también es para ti!

Finalmente, a cada una de las personas que, de una u otra manera, contribuyeron a mi crecimiento personal y profesional, y me acompañaron en este importante logro.

Ruth Mireyla Tarrillo Hernández

A Dios, por darme la vida, salud para lograr mis objetivos.

Con amor a mis padres y hermanos quienes son el pilar fundamental en mi educación ya que, con su amor, apoyo incondicional y su comprensión me ayudaron a salir adelante y a superar los retos que la vida me puso. A mis queridos sobrinos con todo mi cariño y orgullo, les dedico este logro, deseando ser un ejemplo digno para ustedes.

Luz Alicia Vilchez Orlandini

Índice de Contenido

INTRODUCCIÓN	1
CAPÍTULO I. DISEÑO TEÓRICO	6
1.1. Antecedentes	6
1.2. Bases Teóricas	10
1.2.1. Producción de limón	10
1.2.2. Producción de limón en el Perú	11
1.2.3. Series de tiempo y metodología Box–Jenkins	11
1.2.4. Modelos ARIMA y SARIMA.....	12
1.2.5. Prueba de Dickey–Fuller.....	13
1.2.6. Prueba de Phillips–Perron.....	14
1.2.7. Prueba KPSS	14
1.2.8. Funciones de autocorrelación	15
1.2.9. Diagnóstico de residuos	16
1.2.10. Criterios de información	17
1.3. Bases Conceptuales.....	18
CAPÍTULO II. DISEÑO METODOLÓGICO	21
2.1. Diseño de Contrastación de Hipótesis	21
2.2. Población y Muestra	22
2.3. Técnicas, Instrumentos, Equipos y Materiales	22
CAPÍTULO III. RESULTADOS.....	24
3.1. Resultados	24
3.1.1. Resultados según la fase de identificación inicial de la serie de la producción de limón en el Perú, de los años 2010 al 2025.	24

3.1.2. Analizar la estacionariedad y estacionalidad de la producción mensual del limón en el Perú, de los años 2010 al 2025.....	27
3.1.3. Identificación del modelo ARIMA a partir de la serie estacionaria	35
3.1.4 Parámetros del modelo final y diagnóstico de residuos	39
3.1.4. Resultados de la validación y del pronóstico de la producción de limón	45
DISCUSIONES.....	48
CAPÍTULO IV. CONCLUSIONES	52
CAPÍTULO V. RECOMENDACIONES	54
REFERENCIAS.....	55
ANEXOS	60

Índice de tablas

Tabla 1 Prueba de raíz unitaria ADF para la producción de limón en el Perú, de los años 2010 - 2025.	32
Tabla 2 Coeficientes estimados de los modelos SARIMA propuestos.....	35
Tabla 3 Criterios AIC y BIC de los modelos SARIMA propuestos.	38
Tabla 4 Parámetros estimados del modelo final SARIMA (1, 0, 0) (0, 1, 1) ₁₂ sobre la serie diferenciada.....	39
Tabla 5 Prueba de Ljung-Box aplicada a los residuos del modelo final.....	42
Tabla 6 Prueba de normalidad Kolmogorov-Smirnov para los residuos del modelo final.....	45
Tabla 7 Métricas de error en el ajuste y la validación del modelo de la producción de limón en el Perú, 2010 - 2025.	45
Tabla 8 Pronóstico mensual de la producción de limón en el Perú para el año 2025.....	47

Índice de figuras

Figura 1 Serie de tiempo de la producción de limón en el Perú, en los años 2010-2025.	24
Figura 2 Función de autocorrelación simple (ACF) de la producción de limón en el Perú, en los años 2010-2025.	25
Figura 3 Función de autocorrelación parcial (PACF) de la producción de limón en el Perú, en los años 2010-2025.	25
Figura 4 Descomposición de los datos de producción de limón, en los años 2010-2025.	27
Figura 5 Componente de tendencia de la producción de limón en el Perú, en los años 2010-2025.	28
Figura 6 Componente estacional de la producción de limón en el Perú, en los años 2010-2025.	29
Figura 7 Componente residual de la serie descompuesta de la producción de limón en el Perú, en los años 2010-2025.	29
Figura 8 Boxplot de la producción mensual de limón en el Perú, de los años 2010-2025.	31
Figura 9 Función de autocorrelación simple (ACF) de la serie estacionaria.	33
Figura 10 Función de autocorrelación parcial (PACF) de la serie estacionaria.	34
Figura 11 Residuos del modelo final en el tiempo.	40
Figura 12 Función de autocorrelación simple (ACF) de los residuos.	41
Figura 13 Histograma de residuos del modelo final.	43
Figura 14 Gráfico Q–Q de los residuos del modelo final.	44
Figura 15 Pronóstico de la producción mensual de limón para 2025.	46

Resumen

La presente investigación tuvo como objetivo estimar un modelo para pronosticar la producción mensual de limón en el Perú mediante la metodología Box-Jenkins durante el periodo de enero a diciembre durante los años 2010 – 2025. El enfoque fue cuantitativo, no experimental y longitudinal. La muestra estuvo conformada por la producción de limón en miles de toneladas en el Perú, dicha información obtenida del BCR.

Los resultados mostraron que el modelo que mejor pronostica la producción de limón fue un SARIMA (1,0,0) (0,1,1)₁₂, el que presentó $ar1 = 0.7542$, y $sma1 = -0.8550$, con $AIC = 817.4497$, $BIC = 829.9456$, Ljung-Box $Q = 24.172$ ($p = 0.3383$). Se concluye que el modelo estimado es adecuado para describir y pronosticar la dinámica mensual del limón en el Perú.

Palabras clave: series temporales; modelos ARIMA; pronóstico estadístico; producción agrícola; análisis de datos.

Abstract

The objective of this study was to estimate a model to forecast monthly lemon production in Peru using the Box-Jenkins methodology for the period from January through December during the years 2010–2025. The study employed a quantitative, non-experimental, and longitudinal approach. The sample consisted of lemon production data in Peru, expressed in thousands of metric tons, obtained from the BCR.

The results showed that the model that best forecasts lemon production was a SARIMA (1,0,0) (0,1,1)₁₂ model, which had $ar1 = 0.7542$ and $sma1 = -0.8550$, with $AIC = 817.4497$, $BIC = 829.9456$, and Ljung-Box $Q = 24.172$ ($p = 0.3383$). It is concluded that the estimated model is suitable for describing and forecasting the monthly dynamics of lemon production in Peru.

Keywords: time series; ARIMA models; statistical forecasting; agricultural production; data analysis.

INTRODUCCIÓN

La producción de limón constituye un componente estratégico de la citricultura mundial, tanto por su aporte a la seguridad alimentaria como por su incidencia en el comercio agroexportador y en los ingresos de los pequeños productores rurales. A escala global, los volúmenes combinados de limón y lima han mostrado una tendencia creciente durante la última década, con una producción estimada de alrededor de 10 millones de toneladas para la campaña 2023/2024, según proyecciones del Departamento de Agricultura de los Estados Unidos USDA Foreign Agricultural Service (2024). En dicho informe se destaca que el incremento de la oferta en la Unión Europea, Sudáfrica y Turquía compensa la menor producción de México y Estados Unidos, evidenciando la sensibilidad de la citricultura a las condiciones climáticas y fitosanitarias (USDA Foreign Agricultural Service, 2024). Dentro de este contexto, la planificación de la producción y gestión de riesgos en cadenas de valor de productos hortofrutícolas requieren herramientas cuantitativas que sean capaces de representar la dinámica temporal de los volúmenes cosechados y anticipar escenarios de oferta, para orientar decisiones de inversión, abastecimiento e infraestructura en un entorno cada vez más incierto (Thapa et al., 2022).

De acuerdo con los compromisos internacionales adquiridos en la Agenda 2030, la citricultura está directamente relacionada con el Objetivo de Desarrollo Sostenible 2, Hambre Cero, y con sus metas dirigidas a aumentar la productividad y los ingresos de los pequeños productores agrícolas, asegurar sistemas de producción de alimentos sostenibles y reforzar la resiliencia ante el cambio climático y otros desastres (Naciones Unidas, 2022). La ONU ha advertido que las alteraciones climáticas, las tensiones geopolíticas y las últimas crisis sanitarias han anulado progresos en seguridad alimentaria, golpeando más a los países en desarrollo y a las cadenas de productos frescos de gran valor, como los cítricos (Naciones Unidas, 2022). En esta línea, la mejora de la productividad y la estabilidad de cultivos

comerciales como el limón, a través de estrategias basadas en evidencia y en la gestión sostenible de los recursos, es clave para contribuir al aumento sostenible de la producción de alimentos, a la generación de empleo rural y a la reducción de la pobreza agrícola, en coherencia con las metas 2.3 y 2.4 de los ODS.

En el escenario internacional, la producción citrícola se encuentra inmersa en una compleja problemática, donde el juego de factores climáticos, fitosanitarios y de mercado determina una alta volatilidad en los volúmenes y en los precios percibidos por los productores. Un estudio de caso reciente realizado en China documentó que la variabilidad climática altera la calidad del fruto de cítricos dulces al modificar la acidez titulable y los sólidos solubles en función de los patrones de lluvia y temperatura, lo que condiciona la aptitud industrial y la aceptación en los mercados de exportación (Dong et al., 2024). Asimismo, revisiones sobre citricultura y cambio climático han señalado que el aumento de temperaturas medias, la alteración de los regímenes de precipitación y la mayor frecuencia de eventos extremos incrementan el riesgo de mermas de rendimiento, favorecen la dispersión de plagas y enfermedades y obligan a reconfigurar geográficamente las zonas aptas para la producción de cítricos (Rasera et al., 2023).

También, la exposición a contaminantes atmosféricos y a eventos de smog ha sido relacionada con una disminución adicional en la productividad y calidad de los cítricos, al afectar la sanidad de los árboles y alterar procesos fisiológicos clave para la floración y el llenado del fruto (Rasera et al., 2023). Al mismo tiempo, la investigación sobre las cadenas de suministro de cítricos ha resaltado que la presión por cumplir con estándares de inocuidad y sostenibilidad implica mayores exigencias de trazabilidad, inversiones en tecnologías de riego y uso eficiente de insumos, y la necesidad de pronósticos más precisos de volúmenes cosechados para coordinar la logística y la comercialización en mercados internacionales altamente concentrados y competitivos (Wertenbroch & Skiera, 2002). Por tanto, la

problemática internacional de la citricultura requiere modelos analíticos que anticipen oscilaciones de la producción y permitan tomar decisiones estratégicas de adaptación climática y de gestión de riesgos de mercado.

En el caso peruano, la citricultura se ha afianzado como un sector dinámico dentro de la fruticultura de exportación, con un crecimiento sostenido en las últimas décadas, pero también con una elevada exposición a riesgos climáticos y sanitarios. Los últimos informes indican que el país se ubica como uno de los principales exportadores de cítricos del hemisferio sur, y que las exportaciones de mandarina, lima y limón han crecido significativamente, llevando los embarques totales de cítricos a cerca de 250.000 toneladas anuales, aunque con caídas puntuales asociadas a sequías y eventos El Niño que afectan la disponibilidad de agua y la floración (Castillo et al., 2025). Así, un análisis de la campaña 2024 señaló que el Perú exportó 76 752,7 toneladas de limón, lo que representó un crecimiento de 27 % respecto al año previo y un crecimiento medio anual cercano a 18,1 % en el último quinquenio, con una participación predominante de pequeños y medianos productores que enfrentan limitaciones de acceso a financiamiento y tecnología (Agraria, 2025).

Sin embargo, la expansión de la citricultura peruana convive con amenazas fitosanitarias que podrían poner en riesgo su sostenibilidad. Una reciente simulación del escenario de introducción del Huanglongbing en la cadena productiva de naranja en la selva central estimó pérdidas económicas acumuladas del orden de 371 146 mil dólares estadounidenses entre los años 2026 y 2045 en ausencia de un programa fitosanitario nacional, lo que evidencia la vulnerabilidad de los sistemas citrícolas y la necesidad de políticas de prevención y control oportunas (Mercado et al., 2023). También se ha visto que el estudio de la dinámica de los mercados de destino de los cítricos peruanos muestra que productos como el limón, las mandarinas y otros cítricos frescos tienen altos niveles de concentración, con valores del índice de Herfindahl–Hirschman por encima de 2 500 puntos en varios casos, lo

que eleva el riesgo vinculado a cambios de la demanda y a medidas sanitarias o comerciales en unos pocos países importadores (Castillo et al., 2025).

Formulación del Problema de Investigación

¿Cuál es el modelo Arima que pronostica la producción de limón mediante la metodología Box – Jenkins en el Perú en los años 2010 – 2025?

Hipótesis

El Modelo de series de tiempo para pronosticar la producción de limón en el Perú es un modelo SARIMA (p, d, q) (P, D, Q).

Objetivo General

Estimar un modelo Arima para pronosticar la producción de limón en Perú mediante la metodología Box – Jenkins en el Perú en los años 2010 – 2025.

Objetivos Específicos

- Analizar el comportamiento de los componentes de la serie de temporal de la producción mensual de limón en el Perú en los años 2010 – 2025.
- Examinar los supuestos de la serie temporal de la producción de limón en Perú en los años 2010 – 2025 mediante la metodología de Box – Jenkins para la aplicación de los modelos Arima.
- Estimar el modelo Arima para pronosticar la producción mensual de limón en el Perú en los años 2010 – 2025.
- Validar el modelo Arima estimado de la serie de tiempo para pronosticar la producción mensual de limón en Perú, desde el año 2010 hasta 2025.
- Pronosticar la producción mensual del limón en Perú para el año 2025.

La presente investigación justifica metodológicamente a estimar modelos ARIMA y SARIMA para pronosticar la producción mensual de limón en el Perú en el periodo 2010–2025, aplicando rigurosamente la metodología de Box–Jenkins. La literatura especializada ha

mostrado que los modelos de series de tiempo de la familia ARIMA constituyen una herramienta robusta para representar la dinámica de la producción agrícola, evaluar tendencias estructurales y generar predicciones de corto y mediano plazo con errores de pronóstico aceptables, siempre que se cumplan los supuestos de estacionariedad y se realice una adecuada validación de los residuos (Kasthuri & Selvakumar, 2021; Thapa et al., 2022). En este estudio se plantea como objetivo general construir y validar un modelo SARIMA parsimonioso, ajustado a la serie mensual de producción de limón del periodo 2010–2025, a partir del análisis de componentes, la identificación de órdenes estacionales y no estacionales, la verificación de los supuestos de estacionariedad, independencia y normalidad de los errores y la comparación de criterios de información como el AIC y el BIC, con el fin de aportar evidencia empírica que sirva de apoyo a la planificación de la producción y a la gestión de riesgos en la cadena del limón en el Perú.

CAPÍTULO I. DISEÑO TEÓRICO

1.1. Antecedentes

Bhuyan et al. (2025) realizan una modelización del rendimiento de los cinco principales cultivos en Assam—arroz, trigo, papa, colza-mostaza y arhar—para obtener previsiones regionales consistentes para planificar la agricultura. Se tomó una serie de 50 años (1973-74 a 2022-23) y se ajustó ARIMA (0,1,1) para arroz, ARIMA (2,1,0) para trigo, ARIMA (2,2,1) para papa, ARIMA (3,1,1) para colza – mostaza y ARIMA (2,1,2) para arhar seleccionados mediante AIC, BIC y verificación de residuos. El estudio muestra trayectorias pronosticadas relativamente estables para arroz y trigo, y un marcado aumento en papa, con intervalos de confianza que se ensanchan en el tiempo, reflejando una creciente incertidumbre. Los modelos ARIMA, concluyen, brindan pronósticos útiles para la planificación multiespecie y se deben actualizar cuando se tenga más información.

Zulfiqar et al. (2024) analizan la producción de trigo con el fin de evaluar un enfoque híbrido ARIMA(x) que incorpora el método Impulse Indicator Saturation para captar los impulsos en la serie. Se emplean datos anuales de 1948 a 2018 para estimación y se validan proyecciones hasta 2023, comparando ARIMA(x) y ARIMA(2,1,2) por medio de los índices MSE, MAPE y MAD, así como los criterios AIC y BIC. En la estimación ex-ante para el periodo 2023-2024, el modelo ARIMA(x) reporta un valor punto de estimación de 29.916 millones de toneladas, frente a los 29.656 millones pronosticados por el modelo ARIMA(2,1,2), y con menores valores de MSE y MAPE reportados en tablas de resultados. Los autores concluyen que el enfoque híbrido permite mejorar la capacidad de alerta temprana ante posibles brechas de oferta y demanda de trigo, al captar mejor tanto shocks de origen climático como de mercado.

Okorie et al. (2023) pronostican la producción y caracterizan el comportamiento de los rendimientos de 14 cultivos en seis países del África oriental, entre 1961 y 2018, mediante un

análisis de series de tiempo de rendimientos, incluyendo casos de rendimientos extremadamente altos. En el caso de la banana en Burundi se ajusta un ARIMA (2,1,2) tras transformar por Box–Cox y se prueba la adecuación de los residuos mediante Ljung–Box, obteniéndose $Q^* = 1.5746$ con 6 grados de libertad y $p = 0.9544$, lo cual indica que los residuos son compatibles con ruido blanco. Además, reportan para banana en Burundi una media de 60 700 kg/ha, desviación estándar de 12 204.97 kg/ha, asimetría de 3.0704 y curtosis de 13.0916, evidenciando una distribución muy pesada en cola. La prueba de heavy–tailedness basada en Kolmogórov–Smirnov da $p = 0.182$ para banana, lo que apoya el uso de distribuciones de cola pesada. En general, concluyen que los pronósticos ARIMA indican trayectorias relativamente estables hasta 2028, con aumentos notables únicamente en sorgo y café en algunos países.

Pandit et al. (2023) buscan mejorar el pronóstico de rendimiento de los cultivos Rabi en India a través de modelos híbridos ARIMAX–redes neuronales, incorporando el porcentaje de área bajo riego como una variable exógena importante. Se evalúan los híbridos ARIMAX–TDNN, ARIMAX–NLSVR, ARIMAX–WNN, ARIMAX–CNN, ARIMAX–RNN y ARIMAX–LSTM, comparando su desempeño con un ARIMA de referencia, utilizando como métricas el RMSE y el MAPE. El ARIMAX–LSTM obtuvo un incremento promedio de 10.41 % en RMSE y de 12.28 % en MAPE frente al mejor de los otros híbridos, y de 15.83 % y 18.42 % respectivamente frente al ARIMA estándar, lo cual demuestra una mejora considerable en la precisión. Los autores concluyen que la combinación de variables exógenas relevantes con estructuras LSTM permite capturar patrones complejos no lineales y proporciona estimaciones más fiables de los rendimientos agrícolas.

Pokhrel y Adhikari (2023) comparan la predicción de la producción de paddy mediante ARIMA y ARIMAX, con el objetivo de evaluar el aporte de la tierra agrícola como variable exógena en la explicación de la serie. Usando datos anuales 1975–2022, ajustan ARIMA(1,1,7) y ARIMAX(1,1,7) y evalúan desempeño con MAE, MAPE y RMSE en un conjunto de

validación. Para 2022, el modelo ARIMA pronostica 5787.64 t/ha mientras ARIMAX estima 5681.17 t/ha; además ARIMAX reduce MAE de 0.0295 a 0.0247, MAPE de 0.797 a 0.667 y RMSE de 0.0373 a 0.0301, mostrando mejoras consistentes. Los autores concluyen que la inclusión de la disponibilidad de tierra como variable exógena mejora significativamente la precisión de los pronósticos de producción de paddy y apoya políticas de uso eficiente del suelo.

Thapa et al. (2022) desarrollaron un estudio orientado a pronosticar el área, la producción y la productividad de hortalizas en Nepal utilizando modelos ARIMA bajo la metodología Box–Jenkins. El objetivo fue identificar la especificación más adecuada para series anuales de 1977/1978 a 2019/2020, considerando criterios de información AIC y BIC como criterios de selección. Mediante un diseño cuantitativo no experimental y el uso de datos secundarios oficiales, estimaron diferentes modelos ARIMA y encontraron que la estructura ARIMA (0,2,1) resultó apropiada para el área y la producción, mientras que ARIMA (0,2,0) fue la mejor para la productividad. Los resultados mostraron errores de pronóstico relativamente bajos, con valores de MAPE de 2,70 %, 2,40 % y 3,80 % para área, producción y productividad, respectivamente. Los autores concluyeron que la aplicación de ARIMA proporciona proyecciones confiables a cinco años, útiles para la planificación de políticas públicas en el sector agrícola.

En otro contexto, Elakkiya et al. (2024) analizaron la producción de dos de las principales especias de la India, el chile y la cúrcuma, con el objetivo de desarrollar modelos de pronóstico que contribuyeran a mejorar la planificación de las exportaciones agrícolas. Para ello, emplearon datos de series temporales correspondientes al período 1970–2020 y aplicaron modelos ARIMA cuyos parámetros fueron optimizados mediante algoritmos genéticos (ARIMA_GA), utilizando el Error Porcentual Absoluto Medio (MAPE) como criterio de optimización. Los resultados mostraron que el modelo ARIMA_GA obtuvo un mejor

desempeño predictivo que el modelo ARIMA convencional, registrando valores inferiores de Error Cuadrático Medio (RMSE) y MAPE tanto para la producción de chile como de cúrcuma. En particular, el modelo ARIMA_GA (2,1,1) fue identificado como la mejor alternativa para el pronóstico de ambas especias, ya que presenta mayor precisión y capacidad para afrontar problemas de parsimonia y convergencia hacia el óptimo global. Los autores concluyeron que la integración de algoritmos genéticos con modelos ARIMA permite una mejor representación de la complejidad e incertidumbre de los datos agrícolas, constituyendo una herramienta valiosa para la planificación de la producción y el fortalecimiento de las exportaciones del sector agrícola.

Kasthuri y Selvakumar (2021) aplicaron modelos ARIMA para predecir la producción de granos alimenticios en India, a fin de proporcionar insumos cuantitativos para la planificación de la seguridad alimentaria nacional. Se realizó un estudio longitudinal con datos anuales de la producción de varios cultivos, identificándose los modelos ARIMA óptimos mediante un método iterativo que incluyó la prueba de Box–Ljung para comprobar la independencia de los residuos. Los resultados mostraron que los modelos identificados alcanzaron valores moderados de MAPE y capturaron adecuadamente las tendencias de largo plazo de la producción. El autor llegó a la conclusión de que la incorporación de los modelos ARIMA en la planificación agrícola permite anticipar posibles déficits de producción y diseñar estrategias para reducir los riesgos, especialmente en situaciones de variabilidad climática.

Acosta y Chapoñan (2022) estudió el comportamiento temporal de la producción de espárrago mediante el uso de modelos SARIMA, con el propósito de obtener predicciones que ayuden a la producción. La investigación utilizó datos mensuales, y se realizó siguiendo las etapas de identificación, estimación y diagnóstico propuestas por Box y Jenkins, incluyendo pruebas de raíz unitaria y los criterios AIC/BIC. El modelo final presentó coeficientes estadísticamente significativos y residuos sin autocorrelación (verificados mediante la prueba

de Ljung–Box), mientras que los errores de pronóstico se mantuvieron en niveles aceptables para la planificación de corto plazo.

Chávez et al. (2022) realizaron un estudio para la detección de valores atípicos en las series de producción de mango, palta y limón a nivel nacional mediante el uso de modelos ARIMA. Se realizó una investigación aplicada y descriptiva, utilizando índices de producción mensual entre los años 2000 y 2020, ajustando modelos ARIMA con componentes estacionales, como el ARIMA (1,0,1) (0,1,1)₁₂ para el limón, seleccionados con base en AIC y BIC. Los resultados mostraron que en los periodos de mayor producción las series presentaban muchos outliers, por lo que se aplicaron técnicas específicas para la detección de valores atípicos. Se encontró que la corrección de estos datos mejora significativamente la calidad de los pronósticos generados por los modelos ARIMA.

1.2. Bases Teóricas

1.2.1. Producción de limón

A nivel internacional, la producción de limón forma parte de un complejo sistema citrícola, integrado por verdaderos limones, limas y otros híbridos, cuya dinámica está influida por factores climáticos, tecnológicos y comerciales. La producción conjunta mundial de limón y lima para la temporada 2023/2024 se situaría en unos 10 millones de toneladas según las últimas estimaciones del Departamento de Agricultura de los Estados Unidos, con aumentos vinculados a mayores áreas cultivadas y rendimientos en países mediterráneos, el sur de África y América Latina (USDA Foreign Agricultural Service, 2024). También, evaluaciones de la sostenibilidad de las cadenas de cítricos han demostrado que la producción se concentra en un número reducido de países que unen ventajas agroclimáticas con inversión en infraestructura y mejoras genéticas, pero que también enfrentan desafíos crecientes como el estrés hídrico, la degradación de suelos y la presión fitosanitaria (Crenna et al., 2026).

1.2.2. Producción de limón en el Perú

En el caso del Perú, la producción de limón se ha dado principalmente en las regiones de la costa norte, donde las condiciones climáticas permiten ciclos productivos continuos y altos rendimientos por hectárea. Según investigaciones recientes sobre la dinámica de las exportaciones de cítricos, el Perú ha logrado una importante posición como proveedor en el hemisferio sur, con una creciente participación en limas y limones, así como en mandarinas y naranjas (Castillo et al., 2025). La estructura productiva está marcada por la coexistencia de pequeños productores con escasa dotación de tecnología con medianos y grandes productores con acceso a sistemas de riego tecnificado y paquetes tecnológicos modernos, lo que se traduce en heterogeneidad de rendimientos y capacidad de respuesta frente a los choques ambientales y de mercado (Castillo et al., 2025). Esta heterogeneidad dificulta la agregación y modelización de la producción nacional, pero al mismo tiempo hace más pertinente el uso de series agregadas oficiales que integren la diversidad de comportamientos a nivel de finca.

1.2.3. Series de tiempo y metodología Box–Jenkins

Las series temporales son secuencias de observaciones de una variable en intervalos regulares, y su análisis pretende describir la estructura temporal, encontrar patrones sistemáticos y predecir para periodos futuros (Box et al., 2008). La Box–Jenkins se enfoca particularmente en el análisis de series univariadas con modelos autorregresivos integrados de medias móviles (ARIMA), donde el valor de la variable en un periodo se expresa como una combinación lineal de sus valores pasados, de errores aleatorios anteriores y, cuando corresponde, de diferencias para obtener estacionariedad (Box et al., 2008). En el agro, el uso de esta metodología permite capturar tendencias, ciclos y estacionalidades presentes en series de producción, superficie o rendimientos, siempre y cuando se cumplan los supuestos de estacionariedad y de independencia de los residuos. Investigaciones recientes han demostrado que los modelos ARIMA pueden arrojar predicciones con errores moderados, siempre y cuando

los órdenes del modelo sean elegidos apropiadamente y se realicen diagnósticos rigurosos (Thapa et al., 2022).

El enfoque Box–Jenkins se lleva a cabo en cuatro etapas fundamentales: identificación del modelo, estimación de los parámetros, diagnóstico del ajuste y generación (Box et al., 2008). En esta fase de identificación, se analizan la serie original y sus transformaciones, se evalúa la necesidad de diferenciación y se inspeccionan las funciones de autocorrelación y autocorrelación parcial con la finalidad de proponer los órdenes autorregresivos y de medias móviles. En la fase de estimación, se ajustan los modelos candidatos mediante máxima verosimilitud u otros métodos numéricos, obteniendo estimaciones de los parámetros y sus errores estándar (Elakkiya et al., 2024). En la fase de verificación se evalúa el comportamiento de los residuos, verificando que se comporten como ruido blanco mediante pruebas tales como la de Ljung–Box, y se comparan modelos utilizando criterios AIC y BIC, privilegiando especificaciones parsimoniosas (Thapa et al., 2022). Por último, en el paso de predicción se realizan proyecciones para los períodos de interés, evaluando la precisión mediante indicadores como el RMSE, MAE, MAPE, entre otros.

1.2.4. Modelos ARIMA y SARIMA

Los modelos ARIMA se expresan como $ARIMA(p,d,q)$, donde p representa el orden autorregresivo, d el número de diferenciaciones y q el orden de medias móviles. Los operadores de retraso pueden expresar formalmente su estructura, lo cual permite modelar la dependencia temporal de la serie en función de sus propios valores pasados y errores de predicción previos. El atractivo de estos modelos está en su habilidad para capturar de forma parsimoniosa patrones complejos de series con tendencia o dependencia de corto plazo. En el ámbito agrícola, esta característica se traduce en una ventaja, puesto que la producción tiende a seguir ciclos naturales y variaciones del mercado, los cuales pueden ser representados mediante una parametrización bastante reducida (Box et al., 2016).

$$\text{ARIMA}(p,d,q): \phi(B)(1-B)^d y_t = \theta(B)\varepsilon_t$$

Los modelos SARIMA son una ampliación de la especificación ARIMA introduciendo una parte estacional, la cual está representada por los parámetros P, D y Q, y por el período s de la estacionalidad. Esta extensión resulta de gran ayuda cuando la serie muestra patrones repetitivos anuales, trimestrales o mensuales. Para la producción de limón, la estacionalidad mensual suele ser relevante porque la oferta puede concentrarse en algunos meses, dependiendo de la floración, disponibilidad hídrica y gestión de cosecha. Por eso, el modelo SARIMA es capaz de combinar la dinámica regular y la estacional, proporcionando un instrumento flexible para el pronóstico de series agropecuarias (Thapa et al., 2022).

$$\text{SARIMA}(p,d,q)(P,D,Q)_s: \Phi(B^s)(1-B)^d(1-B^d)^D y_t = \theta(B^s)\theta(B)\varepsilon_t$$

1.2.5. Prueba de Dickey–Fuller

El test de Dickey–Fuller aumentado (ADF) es uno de los métodos más empleados para comprobar la existencia de raíz unitaria en una serie temporal y así determinar si la serie es estacionaria o necesita ser diferenciada antes de ajustar un modelo ARIMA. En términos generales, la prueba estima una ecuación de regresión donde la primera diferencia de la serie depende de su rezago, una tendencia determinística y un conjunto de diferencias rezagadas para controlar la autocorrelación serial de los errores. La hipótesis nula plantea que el coeficiente asociado al rezago de la serie es cero, lo que implica la existencia de una raíz unitaria y, por tanto, no estacionariedad; mientras que la hipótesis alternativa plantea que dicho coeficiente es menor que cero, lo que implica estacionariedad alrededor de una media o una tendencia, según la especificación del modelo (Dickey & Fuller, 1979; Said & Dickey, 1984). Su utilidad radica en que permite decidir si la serie debe diferenciarse antes de estimar un ARIMA, evitando inferencias espurias y mejorando la validez de los pronósticos.

$$\text{ADF: } \Delta y_t = \alpha + \beta_t + \gamma y_{t-1} + \sum_{i=1}^p \delta \Delta y_{t-1} + \varepsilon_t$$

1.2.6. Prueba de Phillips–Perron

La prueba de Phillips–Perron (PP) es una prueba de raíz unitaria que permite comprobar la naturaleza estacionaria de una serie, al igual que la ADF, pero incluye una corrección no paramétrica para la autocorrelación y heterocedasticidad de los errores. A diferencia de la ADF, no incluye explícitamente rezagos de diferencias en la ecuación, sino que ajusta el estadístico de prueba con estimadores robustos de la varianza de largo plazo. Esto la hace especialmente útil cuando el investigador sospecha que los errores presentan dependencia serial o variación no constante, condiciones frecuentes en series de producción agrícola y climática. En términos de decisión, si el estadístico PP es suficientemente negativo frente a los valores críticos, se rechaza la hipótesis nula de raíz unitaria y se concluye que la serie es estacionaria o estacionaria tras transformación previa (Phillips & Perron, 1988).

$$PP: \Delta y_t = \alpha + \beta_t + \gamma y_{t-1} + \varepsilon_t$$

1.2.7. Prueba KPSS

La prueba KPSS (Kwiatkowski–Phillips–Schmidt–Shin) se utiliza junto con las pruebas ADF y PP ya que cambia la hipótesis nula: mientras que ADF y PP asumen como nula la presencia de raíz unitaria, KPSS asume como nula la estacionariedad. Su forma permite valorar si la serie es estacionaria en torno a una media o a una tendencia, detectando desviaciones sistemáticas a través de la suma acumulada de los residuos de una regresión sobre constante o sobre constante más tendencia. Por lo tanto, un valor alto de estadístico KPSS lleva a rechazar la hipótesis nula de estacionariedad, indicando la presencia de raíz unitaria o de componentes no estacionarios persistentes (Kwiatkowski et al., 1992). El valor de esta prueba radica en que sirve como contraste complementario y permite constatar la necesidad de diferenciar la serie antes de aplicar ARIMA.

La prueba KPSS evalúa la estacionariedad de una serie temporal considerando como hipótesis nula que la serie es estacionaria. El modelo se expresa como:

$$y_t = \beta_t + r_t + \varepsilon_t$$

donde:

- y_t : valor observado de la serie.
- β_t : componente determinística (constante o tendencia).
- r_t : paseo aleatorio definido por:

$$r_t = r_{t-1} + u_t$$

- ε_t : error estacionario.
- u_t : perturbación aleatoria independiente.

El estadístico KPSS se calcula mediante:

$$KPSS = \frac{1}{T^2 \sigma^2} \sum_{t=1}^T S_t^2$$

donde:

- T : número de observaciones.
- σ^2 : estimador de la varianza de largo plazo.
- r_t : suma acumulada de los residuos:

$$r_t = \sum_{i=1}^t \varepsilon_i$$

1.2.8. Funciones de autocorrelación

La función de autocorrelación simple (ACF) mide la relación lineal entre una serie temporal y sus rezagos. El coeficiente de autocorrelación de un rezago k se define matemáticamente como:

$$\text{ACF: } \rho_k = \frac{\text{Cov}(y_t, y_{t-k})}{\sigma_y^2}$$

Donde $\text{Cov}(y_t, y_{t-k})$ denota la covarianza entre la serie y su valor rezagado k períodos, y σ_y^2 muestran dependencia temporal, y los patrones de caída gradual o picos periódicos indican componentes autorregresivos y estacionales (Box et al., 2016).

La PACF (función de autocorrelación parcial) mide la relación entre una serie temporal y un rezago específico, después de eliminar la influencia de los rezagos intermedios. La PACF para el rezago k está definida matemáticamente como:

$$\text{PACF: } \phi_{kk} = \text{Corr}(y_t, y_{t-k} | y_{t-1}, y_{t-2}, \dots, y_{t-k+1})$$

donde ϕ_{kk} es el coeficiente de autocorrelación parcial del rezago k . Esta herramienta sirve para determinar el orden autorregresivo (p) de un modelo ARIMA, ya que una caída brusca en la PACF suele señalar la existencia de un proceso autorregresivo de cierto orden. Un paso fundamental en la metodología Box–Jenkins para identificar modelos adecuados y parsimoniosos para la predicción es analizar simultáneamente la ACF y la PACF (Box et al., 2016).

1.2.9. Diagnóstico de residuos

El objetivo del diagnóstico de residuos es verificar que el modelo haya capturado de forma adecuada la estructura temporal de la serie y que lo no explicado por el modelo se comporte como ruido blanco. Para ello se comprueba que los residuos tengan media cercana a cero, varianza constante y ausencia de autocorrelación significativa. Se analizan los residuos en el tiempo, su ACF, el histograma y el gráfico Q–Q, gráficamente, y estadísticamente se realiza la prueba de Ljung–Box, entre otras. Una vez que estas comprobaciones resulten satisfactorias, el modelo puede considerarse válido para pronóstico. En los estudios de ARIMA aplicados a la agricultura, la independencia de los residuos y su distribución aproximadamente normal son criterios indispensables para aceptar un modelo final (Ljung & Box, 1978).

$$\text{Ljung–Box: } \phi(B)n^d y_t = \theta(B)\varepsilon_t$$

El test de Kolmogorov–Smirnov se emplea para comprobar si una muestra se extrajo de una distribución específica, normalmente la distribución normal en el análisis de los residuos de los modelos de series temporales. Esta prueba evalúa, en el contexto del diagnóstico del modelo, si las diferencias observadas entre la función de distribución empírica de los residuos

y la distribución teórica esperada son lo suficientemente grandes como para rechazar la hipótesis nula de normalidad. En efecto, su utilidad está en que completa la inspección visual del histograma y del gráfico Q-Q, ofreciendo un criterio formal para valorar la bondad de ajuste de los residuos a los supuestos del modelo. Si la significancia es superior a 0.05, no se rechaza la normalidad, lo que avala la validez inferencial del modelo escogido (Dodge, 2008).

$$\text{Kolmogorov-Smirnov: } D = \text{Sup}_x |F_n(x) - F(x)|$$

1.2.10. Criterios de información

El criterio de información de Akaike (AIC) es una medida de selección de modelos que penaliza el número de parámetros estimados, equilibrando así el ajuste y la complejidad. Cuanto mejor verosimilitud logra el modelo con menos parámetros, menor será su valor, por lo que es muy utilizado en la comparación de modelos ARIMA y SARIMA candidatos. En series de producción agrícola, donde se pueden proponer múltiples especificaciones con órdenes distintos, el AIC ayuda a decidir cuál mantiene mejor relación entre parsimonia y capacidad explicativa (Akaike, 1974).

$$\text{AIC: } AIC = -2 \ln(L) + 2k$$

De manera complementaria, el BIC penaliza con mayor severidad la complejidad del modelo, especialmente cuando el tamaño muestral es grande. Por ello, al comparar varios modelos, se suele observar conjuntamente AIC y BIC para evitar sobreajuste. Si ambos criterios favorecen a una misma especificación, el investigador puede otorgar mayor confianza a dicha elección. En el caso de la producción de limón, estos criterios permiten seleccionar el SARIMA que mejor explica la serie histórica sin incorporar parámetros innecesarios, cumpliendo así el principio de parsimonia que guía la metodología Box-Jenkins (Liu et al., 2023).

$$\text{BIC: } BIC = -2 \ln(L) + k \ln(n)$$

1.3. Bases Conceptuales

Producción de limon: La producción de limón se define como el volumen total del fruto cosechado de *Citrus aurantiifolia* y otras variedades comerciales afines en una determinada unidad geográfica y temporal, y se suele expresar en toneladas métricas. Sintetiza el resultado de la interacción superficie cultivada, rendimiento por hectárea y condiciones climáticas y de manejo y es una variable clave para la planificación de la oferta y evaluación de la seguridad alimentaria en cadenas citrícolas (Castillo et al., 2025).

Serie temporal: Una serie de tiempo es una sucesión de observaciones de una variable, registradas en momentos igualmente espaciados en el tiempo, en la cual su estructura puede comprender componentes de tendencia, estacionalidad, ciclos y ruido aleatorio (Box et al., 2008). El análisis de series de tiempo tiene como objetivo identificar estos componentes, modelar la dependencia temporal entre observaciones y generar pronósticos para periodos futuros, empleando herramientas como los modelos ARIMA y SARIMA (Box et al., 2008).

Metodología Box–Jenkins: El enfoque Box–Jenkins es un procedimiento sistemático para ajustar modelos autorregresivos integrados de medias móviles a series temporales univariadas, el cual se realiza en cuatro etapas: identificación, estimación, verificación y pronóstico (Box et al., 2008). Esta metodología consiste en plantear modelos parsimoniosos de la dinámica temporal de la serie con un número reducido de parámetros, siempre que se cumplan los supuestos de estacionariedad e independencia de los residuos.

Modelo ARIMA: Un modelo $ARIMA(p,d,q)$ es un modelo de series de tiempo que combina componentes autorregresivos de orden p , diferenciaciones de orden d y componentes de medias móviles de orden q para capturar la estructura de dependencia temporal de una serie estacionaria o transformada a estacionaria (Box et al., 2008). Estos modelos se emplean ampliamente en predicción económica, financiera y agrícola por su flexibilidad y relativa facilidad de interpretación.

Modelo SARIMA: El modelo SARIMA extiende la estructura ARIMA incorporando componentes autorregresivos y de medias móviles estacionales, así como diferenciación estacional, para representar series que presentan patrones que se repiten en intervalos regulares, como meses o trimestres (Box et al., 2008). La notación SARIMA(p,d,q)(P,D,Q)_s resume los órdenes de los componentes no estacionales y estacionales, donde s indica la periodicidad del ciclo estacional.

Estacionariedad: La estacionariedad se refiere a la propiedad de una serie de tiempo cuyas características estadísticas, como la media y la varianza, permanecen constantes a lo largo del tiempo (Box et al., 2008). En la práctica, se distinguen estacionariedad en media y en varianza, y su verificación se realiza mediante pruebas de raíz unitaria, como ADF y PP, y pruebas complementarias como KPSS (Kwiatkowski et al., 1992).

Función de autocorrelación (ACF): La función de autocorrelación simple describe el grado de correlación lineal entre los valores de una serie de tiempo y sus propios rezagos, para diferentes valores del desfase temporal (Box et al., 2008). El análisis de la ACF es fundamental en la fase de identificación de modelos ARIMA y SARIMA, ya que permite detectar patrones de dependencia de corto y largo plazo, así como componentes estacionales.

Función de autocorrelación parcial (PACF): La función de autocorrelación parcial mide la correlación entre la serie y sus rezagos una vez controlada la influencia de los rezagos intermedios, lo que resulta especialmente útil para determinar el orden autorregresivo apropiado en modelos ARIMA (Box et al., 2008).

Criterio de información de Akaike (AIC): El AIC es un criterio de selección de modelos que incorpora simultáneamente la bondad de ajuste y la complejidad del modelo, penalizando el número de parámetros estimados (Akaike, 1974). En la modelización ARIMA, se suelen comparar modelos candidatos y seleccionar aquel con menor AIC, siempre que cumpla con los supuestos de independencia y normalidad aproximada de los residuos (Thapa et al., 2022).

Prueba de Ljung–Box: El test de Ljung-Box es un procedimiento estadístico para comprobar la hipótesis nula de que no existe una autocorrelación conjunta en los residuos de un modelo de series temporales hasta un número determinado de rezagos (Ljung & Box, 1978). Un p-valor alto sugiere que no se puede rechazar la hipótesis de ruido blanco, lo cual respalda la bondad del modelo; por el contrario, valores bajos indican autocorrelación residual y la necesidad de reespecificar el modelo.

CAPÍTULO II. DISEÑO METODOLÓGICO

2.1. Diseño de Contrastación de Hipótesis

El estudio utiliza un enfoque cuantitativo, básico y de alcance correlacional, con el objetivo de explicar la relación en el tiempo entre la producción mensual de limón y sus valores pasados, empleando modelos estocásticos de series de tiempo. Desde este punto de vista, se utiliza un diseño basado en la práctica que se centra en usar información ya existente y analizar cuidadosamente los datos históricos, sin cambiar intencionalmente las variables ni asignar al azar los tratamientos, lo cual es adecuado al estudiar fenómenos generales con observaciones hechas en diferentes momentos (Thapa et al., 2022). El enfoque cuantitativo se basa en formular hipótesis claras sobre la presencia de patrones de tendencia, estacionalidad y correlación entre sí en la producción de limón. Estas hipótesis se comparan con datos reales usando pruebas de raíz unitaria, coeficientes de autocorrelación y criterios de información, lo que permite elegir el modelo ARIMA o SARIMA más sencillo y efectivo para hacer predicciones (Elakkiya et al., 2024).

El diseño metodológico utilizado no es experimental ni transversal, sino que es longitudinal y no experimental, ya que se observa una sola serie de tiempo de manera mensual durante el periodo 2010–2025. El investigador no interviene en la asignación de los valores de la variable dependiente ni en las condiciones de producción (Hernández & Mendoza, 2018). En este contexto, la variable que se estudia es la producción mensual de limón en el Perú, medida en toneladas y registrada constantemente en fuentes oficiales, lo que nos permite observar cómo ha evolucionado el fenómeno y reconocer si hay componentes que ocurren de manera sistemática. El diseño longitudinal permite analizar cambios estructurales relacionados con eventos climáticos o del mercado, así como medir qué tan bien el modelo elegido reproduce la dinámica real y genera

pronósticos a corto plazo, algo que se sigue haciendo comúnmente en estudios de predicción agrícola y de commodities (Hamjah, 2014).

2.2. Población y Muestra

La población objetivo es la totalidad de la producción de limones elaborada en el territorio peruano, entendida como el conjunto de valores que describen su volumen mes a mes a lo largo del tiempo. Los datos disponibles se refieren a una serie de tiempo total y en forma agregada, de modo que la muestra del estudio consiste en 14 años de series mensuales observadas de producción de limones en el Perú durante el período enero de 2010 a diciembre de 2024, obtenido del Banco Central de Reserva del Perú (2025), la cual constituye un censo de observaciones para el periodo de análisis, al igual que en estudios previos que utilizan series oficiales para modelar la producción agrícola y de frutas (Hernández & Mendoza, 2018). Esto representa un censo de observaciones para el período de análisis. Al evitar por completo cualquier error de muestreo, este enfoque censal garantiza que los patrones identificados durante el modelado tanto (a) ocurren en una magnitud que es estadísticamente medible y (b) son demostrativos de la dinámica nacional de la producción de limones tal como se refleja en las estadísticas.

2.3. Técnicas, Instrumentos, Equipos y Materiales

Las técnicas empleadas son de carácter documental y estadístico. En primer lugar, se realiza una revisión y extracción sistemática de la información de producción mensual de limón desde fuentes oficiales de estadística agropecuaria, la cual se registra en una ficha de recojo de datos que consigna para cada mes el volumen producido, las unidades de medida y las eventuales notas de revisión (Hamjah, 2014). En segundo lugar, la serie se importa al software R para su procesamiento, donde se aplican procedimientos de limpieza, transformación logarítmica, descomposición estacional y diferenciación regular y estacional, de acuerdo con los criterios de la

metodología Box–Jenkins (Box et al., 2008). Los instrumentos centrales del análisis son las funciones de autocorrelación y autocorrelación parcial, las pruebas de raíz unitaria y de estacionariedad, los criterios de información AIC y BIC, y las pruebas de diagnóstico sobre residuos, como Ljung–Box y Kolmogorov–Smirnov, complementadas con la inspección gráfica de los residuos y de los pronósticos (Elakkiya et al., 2024; Thapa et al., 2022).

El proceso metodológico se desarrolla en los pasos básicos del método Box–Jenkins: Identificación, Estimación, Verificación y Pronóstico. En la etapa de identificación se examina la serie original y las transformaciones de esta serie, con el fin de evaluar la existencia de tendencia, estacionalidad y cambios en la varianza, el uso de descomposición STL, pruebas ADF, PP, KPSS, inspección de las funciones ACF y PACF (Box et al., 2008; Kasthuri & Selvakumar, 2021). Se proponen modelos ARIMA y SARIMA candidatos a partir de dichos insumos que posteriormente son estimados por máxima verosimilitud o con algoritmos de optimización, registrándose los coeficientes, errores estándar, y niveles de significancia (Elakkiya et al., 2024). La fase de verificación incluye el análisis de residuos, que se realiza a través de la prueba de Ljung–Box, la aproximación a la normalidad mediante pruebas de bondad de ajuste y gráficos Q–Q, y el análisis de la comparación de modelos a partir de los valores de AIC y BIC, en favor de las especificaciones parsimoniosas, como se expondrá en el capítulo de resultados empíricas del estudio. Finalmente, se utiliza el modelo SARIMA seleccionado para realizar proyecciones de la producción mensual de limón y estimar intervalos de confianza de los pronósticos, comparando las proyecciones con un subconjunto de datos reservado para validación y evaluando el desempeño del modelo propuesto con métricas convencionales como el RMSE, MAE, MAPE, y el estadístico de Theil U, siguiendo el ejemplo de las aplicaciones recientes de los modelos ARIMA en el pronóstico de la producción de un cultivo (Elakkiya et al., 2024; Kasthuri & Selvakumar, 2021; Thapa et al., 2022).

CAPÍTULO III. RESULTADOS


3.1. Resultados

En este capítulo se presentan los resultados del análisis de la producción mensual de limón en el Perú durante el periodo 2010–2025, dicho resultados se obtuvieron aplicando la metodología de Box–Jenkins sobre la serie temporal. Se describe e interpreta las figuras y tablas generadas en el software R.

3.1.1. Resultados según la fase de identificación inicial de la serie de la producción de limón en el Perú, de los años 2010 al 2025.

Figura 1

Serie de tiempo de la producción de limón en el Perú, en los años 2010-2025.




La Figura 1 muestra la trayectoria original de la producción mensual de limón, donde se observa un patrón claramente estacional con picos recurrentes cada doce meses y una tendencia general creciente hacia el final del periodo. Entre 2010 y 2014 la producción oscila en torno a niveles intermedios, mientras que a partir de 2018 se evidencian valores máximos, lo que indica un incremento en la capacidad productiva. También se aprecian caídas pronunciadas en algunos años, compatibles con eventos climáticos o perturbaciones de mercado que afectan

coyunturalmente la oferta. Esta lectura preliminar permite afirmar que la serie no es puramente aleatoria y justifica la aplicación de técnicas de descomposición y transformación para cumplir los supuestos requeridos por la metodología de Box–Jenkins.

Figura 2


Función de autocorrelación simple (ACF) de la producción de limón en el Perú, en los años 2010-2025.



En la Figura 2 se muestra la función de autocorrelación simple de la serie original, en la que sobresalen valores significativamente distintos de cero para los primeros rezagos y, muy especialmente, para los rezagos cada doce meses. El patrón encontrado confirma una fuerte dependencia temporal de corto plazo y un componente estacional anual bien definido. También, las autocorrelaciones decrecen lentamente, lo que sugiere que la serie no es ruido blanco, sino que contiene estructura que se puede modelar con términos autorregresivos y de media móvil. Box–Jenkins considera que esta información indica que el modelo debe contener componentes estacionales, y constituye el punto de partida para la identificación de los órdenes p , q , P y Q .

Figura 3

Función de autocorrelación parcial (PACF) de la producción de limón en el Perú, en los años 2010-2025.




En la Figura 3 se muestra la función de autocorrelación parcial de la serie original, donde el primer rezago tiene un valor elevado y le siguen varios rezagos iniciales con autocorrelaciones parciales positivas menores, aunque aún visibles. Este comportamiento es consistente con la presencia de uno o más términos autorregresivos en la estructura del modelo. Adicionalmente, se observan algunos rezagos estacionales con valores que se acercan a los límites de significancia, lo que refuerza la idea de un patrón anual. La PACF contribuye así a orientar la elección de órdenes AR para los modelos candidatos y, en conjunto con la ACF, constituye un insumo clave en la fase de identificación de la metodología Box–Jenkins.

3.1.2. Analizar la estacionariedad y estacionalidad de la producción mensual del limón en el Perú, de los años 2010 al 2025.

Figura 4


Descomposición de los datos de producción de limón, en los años 2010-2025.



En la Figura 4 se reitera la serie observada para enfatizar la separación posterior de sus componentes mediante la descomposición. En ella se aprecia nuevamente la estacionalidad acentuada y las oscilaciones de amplitud variable a lo largo del tiempo. Esta representación sirve como referencia para comparar visualmente el efecto de la tendencia, la estacionalidad y el componente residual que se obtendrán en las figuras siguientes. Su análisis confirma que la producción de limón responde tanto a factores de ciclo anual como a variaciones estructurales de mayor plazo, lo que justifica el uso de modelos SARIMA en lugar de modelos puramente ARIMA no estacionales.

Figura 5


Componente de tendencia de la producción de limón en el Perú, en los años 2010-2025



La Figura 5 presenta el componente de tendencia extraído mediante la descomposición. Se observa un incremento gradual de la producción entre el año 2010 y 2014, seguido de una caída marcada alrededor del año 2016, para luego registrar una recuperación sostenida hasta 2024. La presencia de una tendencia indica que la serie original no es estacionaria en nivel, lo que refuerza la necesidad de aplicar transformaciones y diferenciaciones antes de estimar el modelo ARIMA.

Figura 6


Componente estacional de la producción de limón en el Perú, en los años 2010-2025



La Figura 6 muestra la componente estacional, caracterizada por un patrón prácticamente sin cambios en todo el periodo de estudio. Se observan cambios positivos y negativos que se repiten con el mismo comportamiento de la producción cada año, lo que refleja una estacionalidad muy estable en la producción de limón. Este resultado indica que los meses de mayor y menor producción se mantienen constantes en el tiempo, probablemente asociados a condiciones climáticas y ciclos de cosecha propios del cultivo. La constancia de la estacionalidad facilita la incorporación de un término estacional de periodo doce en el modelo SARIMA, ya que el comportamiento anual puede ser capturado mediante diferencias estacionales y parámetros específicos.

Figura 7


Componente residual de la serie descompuesta de la producción de limón en el Perú, en los años 2010-2025.



En la Figura 7 se aprecia el componente residual resultante de la descomposición, el cual oscila alrededor de cero con variaciones de diferente magnitud a lo largo del tiempo. No se observa un patrón sistemático evidente, lo que sugiere que buena parte de la estructura de la serie ha sido capturada por la tendencia y la estacionalidad. La ausencia de un comportamiento periódico claro en esta componente respalda la validez de la descomposición realizada.

Figura 8

Boxplot de la producción mensual de limón en el Perú, de los años 2010-2025.



En la Figura 8 se muestra diferencias claras en la distribución mensual de la producción. Las medianas más elevadas se concentran principalmente entre febrero y mayo, destacando marzo y abril, mientras que los niveles más bajos se presentan entre agosto y octubre. A partir de noviembre se observa una recuperación que continúa hacia diciembre y los primeros meses del año siguiente. La presencia de estas diferencias sistemáticas entre meses confirma la estacionalidad anual de la serie y respalda la utilización de una periodicidad de doce meses en el modelo SARIMA.

Tabla 1

Prueba de raíz unitaria ADF para la producción de limón en el Perú, de los años 2010 - 2025.

Estadístico	Valor	Orden de rezago	p-valor
Dickey–Fuller	-3.4784	5	0.0466
Phillips-Perron	-45.5055	4	0.0100

Hipótesis:

Test de Dickey-Fuller (ADF)

H₀: la serie no es estacionaria (tiene raíz unitaria)

H₁: la serie es estacionaria

Test de Phillips-Perron (PP)


H₀: la serie no es estacionaria

H₁: la serie es estacionaria

En la Tabla 1 se presentan los resultados de las pruebas de estacionariedad aplicadas a la serie original de la producción de limón en el Perú durante el periodo 2010–2025. La prueba Augmented Dickey–Fuller test (ADF) reporta un estadístico de -3.4784 con un p-valor de 0.0466, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria. De igual manera al aplicar la prueba Phillips–Perron test también rechaza dicha hipótesis, reforzando esta evidencia.

Figura 9


Función de autocorrelación simple (ACF) de la serie estacionaria



La Figura 9 muestra la ACF de la serie estacionaria. Los primeros rezagos conservan autocorrelaciones positivas importantes, mientras que alrededor del rezago 12 se observan autocorrelaciones negativas relacionadas con la estructura estacional. A medida que aumenta el rezago, la mayoría de los coeficientes tiende a disminuir. Este patrón sugiere la presencia de componentes de bajo orden en la parte no estacional y un componente estacional que debe ser incluido en la especificación SARIMA.

Figura 10

Función de autocorrelación parcial (PACF) de la serie estacionaria



La Figura 10 presenta la PACF de la serie estacionaria. El primer rezago muestra una autocorrelación parcial positiva elevada, mientras que alrededor de los rezagos estacionales aparecen algunos picos relevantes. En los demás rezagos, la mayor parte de los valores se encuentra cerca de cero. En conjunto con la ACF, este comportamiento orienta hacia estructuras parsimoniosas; sin embargo, para evitar una selección basada únicamente en la inspección gráfica, se procedió a evaluar sistemáticamente múltiples combinaciones SARIMA.

3.1.3. Identificación del modelo ARIMA a partir de la serie estacionaria

El procedimiento `auto.arima` se utilizó inicialmente como guía para identificar los órdenes de diferenciación. Este procedimiento propuso un ARIMA (1,0,0) (0,1,1)₁₂ con deriva y determinó $d = 0$ y $D = 1$. Posteriormente se evaluaron múltiples combinaciones de los órdenes p , q , P y Q mediante máxima verosimilitud. A diferencia del análisis anterior, la selección final se restringió exclusivamente a modelos en los que todos los coeficientes estimados resultaron significativos al 5 %. De este conjunto se conservaron los diez modelos con menor AICc para su presentación y comparación.

Tabla 2

Coeficientes estimados de los modelos SARIMA propuestos.

Parámetro	Estimación	Error estándar	Z	p-valor
Modelo 1: SARIMA(1,0,0)(0,1,1)[12] con deriva				
ar1	0.7542	0.0504	14.9746	<0.001
sma1	-0.8550	0.0848	-10.0841	<0.001
drift	0.0670	0.0166	4.0307	<0.001
Modelo 2: SARIMA(0,0,4)(0,1,1)[12] con deriva				
ma1	0.8640	0.0770	11.2206	<0.001
ma2	0.6101	0.0953	6.4007	<0.001
ma3	0.4177	0.0971	4.3032	<0.001
ma4	0.2237	0.0793	2.8230	0.0048
sma1	-0.9181	0.1313	-6.9921	<0.001
drift	0.0669	0.0113	5.9175	<0.001
Modelo 3: SARIMA(0,0,3)(0,1,1)[12] con deriva				
ma1	0.8103	0.0755	10.7325	<0.001
ma2	0.5231	0.0774	6.7601	<0.001
ma3	0.2351	0.0682	3.4452	<0.001
sma1	-0.8823	0.1036	-8.5203	<0.001
drift	0.0671	0.0103	6.5455	<0.001

Parámetro	Estimación	Error estándar	Z	p-valor
Modelo 4: SARIMA(0,0,2)(0,1,1)[12] con deriva				
ma1	0.8073	0.0732	11.0312	<0.001
ma2	0.3557	0.0583	6.0974	<0.001
sma1	-0.8696	0.0934	-9.3126	<0.001
drift	0.0672	0.0092	7.3006	<0.001
Modelo 5: SARIMA(0,0,4)(2,1,0)[12] con deriva				
ma1	0.8513	0.0783	10.8748	<0.001
ma2	0.5996	0.0978	6.1286	<0.001
ma3	0.3903	0.0951	4.1060	<0.001
ma4	0.1681	0.0771	2.1810	0.0292
sar1	-0.5361	0.0765	-7.0084	<0.001
sar2	-0.2765	0.0762	-3.6265	<0.001
drift	0.0674	0.0309	2.1840	0.0290
Modelo 6: SARIMA(0,0,3)(2,1,0)[12] con deriva				
ma1	0.8055	0.0746	10.7904	<0.001
ma2	0.5294	0.0780	6.7883	<0.001
ma3	0.2595	0.0702	3.6992	<0.001
sar1	-0.5485	0.0765	-7.1669	<0.001
sar2	-0.2814	0.0755	-3.7284	<0.001
drift	0.0682	0.0268	2.5456	0.0109
Modelo 7: SARIMA(0,0,3)(1,1,0)[12] con deriva				
ma1	0.8078	0.0748	10.8058	<0.001
ma2	0.5216	0.0765	6.8157	<0.001
ma3	0.2647	0.0747	3.5441	<0.001
sar1	-0.4262	0.0707	-6.0308	<0.001
drift	0.0689	0.0351	1.9616	0.0498
Modelo 8: SARIMA(0,0,2)(2,1,0)[12] con deriva				
ma1	0.7899	0.0738	10.7012	<0.001
ma2	0.3443	0.0595	5.7853	<0.001
sar1	-0.5524	0.0758	-7.2841	<0.001

Parámetro	Estimación	Error estándar	Z	p-valor
sar2	-0.2776	0.0760	-3.6518	<0.001
drift	0.0687	0.0230	2.9918	0.0028
Modelo 9: SARIMA(0,0,1)(0,1,1)[12] con deriva				
ma1	0.6248	0.0444	14.0574	<0.001
sma1	-0.8081	0.0803	-10.0646	<0.001
drift	0.0675	0.0088	7.6524	<0.001
Modelo 10: SARIMA(0,0,2)(1,1,0)[12] con deriva				
ma1	0.8069	0.0733	11.0036	<0.001
ma2	0.3324	0.0578	5.7540	<0.001
sar1	-0.4350	0.0704	-6.1812	<0.001
drift	0.0692	0.0300	2.3088	0.0210

En la Tabla 2 presenta los coeficientes estimados de los diez mejores modelos cuyos parámetros cumplen el criterio de significancia estadística al 5 %. En todos los modelos incluidos, cada término autorregresivo, de media móvil, estacional y de deriva presenta un p-valor inferior a 0.05. En particular, el Modelo 1 presenta un término AR (1), un término de media móvil estacional SMA (1) y una deriva, todos altamente significativos. Los modelos restantes incorporan estructuras de media móvil más amplias o términos autorregresivos estacionales adicionales, manteniendo igualmente la significancia individual de sus parámetros. De este modo, la comparación posterior mediante criterios de información se realiza únicamente entre especificaciones estadísticamente válidas.

Tabla 3*Criterios AIC y BIC de los modelos SARIMA propuestos.*

Modelo	AIC	BIC
Modelo 1: SARIMA(1,0,0)(0,1,1)[12] con deriva	817.4497	829.9456
Modelo 2: SARIMA(0,0,4)(0,1,1)[12] con deriva	819.6946	841.5624
Modelo 3: SARIMA(0,0,3)(0,1,1)[12] con deriva	825.5120	844.2558
Modelo 4: SARIMA(0,0,2)(0,1,1)[12] con deriva	834.4208	850.0406
Modelo 5: SARIMA(0,0,4)(2,1,0)[12] con deriva	842.4217	867.4134
Modelo 6: SARIMA(0,0,3)(2,1,0)[12] con deriva	845.2484	867.1161
Modelo 7: SARIMA(0,0,3)(1,1,0)[12] con deriva	856.2252	874.9690
Modelo 8: SARIMA(0,0,2)(2,1,0)[12] con deriva	856.2841	875.0278
Modelo 9: SARIMA(0,0,1)(0,1,1)[12] con deriva	863.3997	875.8956
Modelo 10: SARIMA (0,0,2) (1,1,0)[12] con deriva	866.7563	882.3761

En la Tabla 3 se compara los diez modelos candidatos mediante los criterios AIC, AICc y BIC. El Modelo 1, SARIMA (1,0,0) (0,1,1)₁₂ con deriva, presenta los menores valores en los tres criterios, con AIC = 817.4497, AICc = 817.6951 y BIC = 829.9456. El Modelo 2 alcanza un AICc de 820.3946, mientras que las restantes especificaciones registran valores progresivamente superiores. Considerando que todos los modelos de esta tabla cumplen previamente el criterio de significancia de sus coeficientes, el menor AICc y la menor complejidad relativa del Modelo 1 sustentan su selección como modelo final.

3.1.4 Parámetros del modelo final y diagnóstico de residuos

Tabla 4


Parámetros estimados del modelo final SARIMA (1, 0, 0) (0, 1, 1)₁₂ sobre la serie diferenciada.

Parámetro	Valor	Error estándar	t-valor	p-valor
ar1	0.7542	0.0504	14.9746	<0.001
sma1	-0.8550	0.0848	-10.0841	<0.001
drift	0.0670	0.0166	4.0307	<0.001

En la Tabla 4 presenta los parámetros del modelo final SARIMA (1,0,1) (0,1,1)₁₂ con deriva. El coeficiente AR (1) es positivo y estadísticamente significativo, lo que evidencia una dependencia importante respecto del comportamiento reciente de la serie. El término SMA (1) es negativo y altamente significativo, reflejando un efecto corrector de las innovaciones ocurridas doce meses antes. Finalmente, la deriva es positiva y significativa, indicando un cambio promedio gradual en la serie una vez considerada la diferenciación estacional. Los intervalos de confianza al 95 % no incluyen cero en ninguno de los parámetros.

Figura 11


Residuos del modelo final en el tiempo



En la Figura 11 muestra la evolución de los residuos del modelo final. Los errores fluctúan alrededor de cero y no presentan una tendencia o patrón temporal claramente definido. Aunque se observan algunos valores de mayor magnitud en determinados periodos, estos aparecen de manera aislada. Este comportamiento sugiere que el modelo ha capturado adecuadamente la mayor parte de la estructura sistemática de la serie, quedando principalmente variaciones aleatorias.

Figura 12

Función de autocorrelación simple (ACF) de los residuos



En la Figura 12 se muestra la ACF de los residuos del modelo final. La mayoría de las autocorrelaciones se encuentran dentro de las bandas de confianza y no se observa una secuencia sistemática de autocorrelaciones. Este comportamiento gráfico es consistente con residuos aproximadamente independientes y se complementa con la prueba de Ljung–Box para verificar formalmente la ausencia de autocorrelación conjunta.

Tabla 5

Prueba de Ljung-Box aplicada a los residuos del modelo final

Estadístico Q	Grados de libertad	p-valor	Conclusión
24.172	22	0.3383	No se rechaza H0 de ausencia de autocorrelación

Hipótesis:

Test de Ljung–Box (autocorrelación)


H₀: los residuos no están autocorrelacionados (ruido blanco)

H₁: los residuos sí están autocorrelacionados

En la Tabla 5 muestran los resultados de la prueba de Ljung-Box obtuvo un estadístico de 24.172, con 22 grados de libertad y un valor p de 0,3383, este valor superior al nivel de significancia del 5 %. Por lo tanto, no se rechaza la hipótesis nula de ausencia de autocorrelación en los residuos, lo que respalda la adecuación del modelo final en la captura de la estructura temporal de la producción.

Figura 13


Histograma de residuos del modelo final



En la Figura 13 puede observarse el histograma de los residuos, donde se puede apreciar una distribución relativamente simétrica, concentrada alrededor de cero, aunque con cierto ligero sesgo y colas algo alargadas. La mayor parte de los desechos se encuentran en un rango estrecho, lo que sugiere que los errores de predicción tienden a ser de magnitud pequeña. En series reales es normal encontrar algunos valores más alejados, lo que refleja que en ocasiones se producen desviaciones importantes poco frecuentes. En general, el histograma sugiere que la suposición de normalidad es razonable, pero debe ser comprobada formalmente mediante la prueba de Shapiro-Wilk y el gráfico Q-Q.

Figura 14

Gráfico Q-Q de los residuos del modelo final.



En la Figura 14 compara los cuantiles observados de los residuos con los cuantiles esperados bajo una distribución normal. La mayor parte de los puntos sigue de manera aproximada la línea de referencia, especialmente en la parte central. En los extremos existen algunas desviaciones, pero estas no muestran una separación suficientemente pronunciada como para concluir, únicamente de manera gráfica, un incumplimiento severo del supuesto de normalidad.

Tabla 6*Prueba de normalidad Kolmogorov-Smirnov para los residuos del modelo final*

Estadístico	p-valor	Conclusión
0.063799	0.07119	No se rechaza H0 de normalidad

Hipótesis:

Test de Kolmogorov-Smirnov (normalidad)

H₀: los residuos siguen una distribución normal

H₁: los residuos no siguen una distribución normal

En la Tabla 6 se presenta los resultados de la prueba de normalidad de Kolmogorov–Smirnov, este Test es aplicado a los residuos del modelo final estimado. El resultado obtenido fue 0.063799, acompañado de un p-valor de 0.07119, superior al nivel de significancia del 5 %. Este resultado es consistente con el comportamiento observado en el histograma y en el gráfico Q–Q, por lo que los residuos del modelo final pueden considerarse compatibles con una distribución normal para los fines del análisis.

3.1.4. Resultados de la validación y del pronóstico de la producción de limón

Tabla 7*Métricas de error en el ajuste y la validación del modelo de la producción de limón en el Perú, 2010 - 2025.*


Conjunto	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Entrenamiento	-0.047	2.4917	1.8778	-2.0353	9.8403	0.5322	0.0919	—
Prueba	3.3468	3.9233	3.4243	10.6803	10.9476	0.9704	0.1995	1.3134

En la Tabla 7 resume las métricas obtenidas durante el entrenamiento y la validación. En el conjunto de entrenamiento, el modelo presenta un RMSE de 2.4917 y un MAPE de 9.84 %. En

el conjunto de prueba, el RMSE aumenta a 3.9233 y el MAPE a 10.95 %, lo que refleja una reducción moderada de la precisión al trabajar con observaciones no utilizadas en la estimación. El MASE de 0.9704 es inferior a uno, indicando un desempeño ligeramente mejor que el método ingenuo de referencia según esta medida, mientras que el Theil's U de 1.3134 evidencia que la comparación depende del criterio empleado.

Figura 15

Pronóstico de la producción mensual de limón para 2025



La Figura 15 compara los valores reales con los pronósticos generados para el periodo de validación. El modelo reproduce el patrón estacional general, identificando niveles altos al inicio del periodo, una disminución posterior y una recuperación hacia el cierre. Las observaciones reales se mantienen, en términos generales, dentro de los intervalos de predicción, aunque se presentan diferencias entre la trayectoria puntual pronosticada y la observada. El gráfico confirma una capacidad predictiva razonable para representar la dinámica estacional fuera de muestra.

Tabla 8

Pronóstico mensual de la producción de limón en el Perú para el año 2025.

Mes	Pronóstico	Lím. inf. 95%	Lím. sup. 95%
Enero	33.3099	28.2332	38.3865
Febrero	35.2767	28.9191	41.6343
Marzo	36.8142	29.8320	43.7963
Abril	35.1944	27.8807	42.5080
Mayo	32.5335	25.0379	40.0292
Junio	28.3978	20.8006	35.9951
Julio	23.8660	16.2116	31.5204
Agosto	21.2877	13.6010	28.9744
Setiembre	21.0333	13.3284	28.7382
Octubre	23.2839	15.5689	30.9990
Noviembre	26.0429	18.3223	33.7635
Diciembre	30.2827	22.5594	38.0061

En la Tabla 8 muestra que el mayor valor pronosticado se presenta en marzo de 2025, con 36.81, seguido por febrero y abril. A partir de mayo se proyecta una reducción progresiva hasta septiembre, mes que registra el menor valor puntual con 21.03. Posteriormente, el modelo estima una recuperación durante octubre, noviembre y diciembre. Los intervalos al 95 % son más amplios que los intervalos al 80 %, reflejando el aumento esperado de la incertidumbre al utilizar un nivel de confianza mayor.

DISCUSIONES

En relación con el objetivo general, la aplicación de la metodología Box–Jenkins permitió seleccionar una estructura parsimoniosa y estadísticamente sustentada para representar la producción mensual de limón en el Perú. Entre los modelos cuyos coeficientes resultaron significativos al 5 %, el SARIMA (1,0,0) (0,1,1)₁₂ con deriva presentó los menores criterios de información, con $AIC = 817.4497$, $AICc = 817.6951$ y $BIC = 829.9456$. Este procedimiento coincide con Bhuyan et al. (2025), quienes seleccionaron modelos ARIMA para distintos cultivos mediante AIC y BIC y verificaron sus residuos, aunque las estructuras finales variaron según la dinámica particular de cada serie. Del mismo modo, Thapa et al. (2022) utilizaron la metodología Box–Jenkins y criterios de información para identificar modelos de producción agrícola, confirmando que la elección de una especificación parsimoniosa depende de la estructura temporal de los datos. En el presente estudio, la incorporación de una componente autorregresiva, una media móvil estacional y una deriva permitió representar conjuntamente la dependencia de corto plazo, la estacionalidad anual y el cambio gradual de la serie.

Respecto al primer objetivo específico, la serie original evidenció una estructura temporal claramente no aleatoria, con estacionalidad anual y cambios en el nivel de producción. La descomposición STL mostró una disminución importante alrededor de 2017–2018 y una recuperación posterior, mientras que el componente estacional mantuvo un patrón recurrente de doce meses. Asimismo, la ACF presentó autocorrelaciones elevadas en los primeros rezagos y en múltiplos de doce, y la PACF destacó una dependencia importante en el primer rezago. Estos hallazgos son consistentes con Bhuyan et al. (2025), quienes observaron cambios de nivel y trayectorias estructuradas en series agrícolas extensas, y con Okorie et al. (2023), quienes identificaron dependencia temporal y patrones sistemáticos en rendimientos agrícolas. En

consecuencia, los resultados respaldan la pertinencia de emplear modelos estacionales para una serie mensual como la producción de limón.

En cuanto al segundo objetivo específico, la identificación automática determinó que no era necesaria una diferenciación regular ni una transformación logarítmica, sino únicamente una diferenciación estacional de primer orden, con $d = 0$ y $D = 1$. Después de este tratamiento, la prueba ADF obtuvo -3.4784 con $p = 0.0466$, Phillips–Perron registró -45.5055 con $p = 0.0100$ y KPSS alcanzó 0.1394 con $p = 0.1000$. La lectura conjunta de estas pruebas confirmó la estacionariedad de la serie utilizada para la modelación. Este resultado se relaciona con el enfoque descrito por Hamjah (2014), quien destacó la necesidad de verificar la estacionariedad antes de estimar modelos ARIMA, y con Okorie et al. (2023), quienes también ajustaron previamente la serie antes de la modelación. Sin embargo, a diferencia de este último antecedente, en la presente investigación no fue necesario aplicar una transformación de escala, evidenciando que el tratamiento requerido depende de las características específicas de cada serie.

En relación con el tercer objetivo específico, la búsqueda sistemática de modelos permitió restringir la comparación a especificaciones cuyos coeficientes fueran estadísticamente significativos. El modelo final SARIMA $(1,0,0) (0,1,1)_{12}$ con deriva presentó $ar1 = 0.7542$, $sma1 = -0.8550$ y $deriva = 0.0670$, todos con $p < 0.001$. El coeficiente autorregresivo refleja una dependencia positiva respecto del comportamiento reciente de la serie, mientras que el término de media móvil estacional representa un efecto corrector asociado a las innovaciones de doce meses atrás; la deriva, por su parte, recoge un cambio promedio gradual. La selección mediante AIC, AICc y BIC mantiene la lógica utilizada por Thapa et al. (2022) y Bhuyan et al. (2025), quienes compararon modelos agrícolas bajo criterios de información y parsimonia. La diferencia principal

es que en este estudio se incorporó, además, la exigencia de significancia individual de todos los parámetros antes de realizar la comparación final.

Con respecto al cuarto objetivo específico, la validación mostró que el modelo conserva capacidad predictiva fuera de muestra, aunque con un incremento esperado del error respecto del ajuste. En entrenamiento se obtuvo $RMSE = 2.4917$, $MAE = 1.8778$ y $MAPE = 9.8403 \%$, mientras que en prueba se alcanzó $RMSE = 3.9233$, $MAE = 3.4243$ y $MAPE = 10.9476 \%$. El MASE fue 0.9704 , valor ligeramente inferior a uno, lo que indica un desempeño favorable frente al método ingenuo utilizado como referencia para esta métrica. Además, Ljung–Box registró $Q = 24.172$ con $p = 0.3383$, por lo que no se evidenció autocorrelación residual, y Lilliefors obtuvo $D = 0.0638$ con $p = 0.0712$, sin rechazo de normalidad. Estos resultados coinciden con Okorie et al. (2023) y Kasthuri y Selvakumar (2021), quienes consideraron la ausencia de autocorrelación residual como un criterio central para validar modelos ARIMA aplicados a producción agrícola. Aunque estudios como Thapa et al. (2022) reportaron errores porcentuales menores, las diferencias en periodicidad, horizonte y tipo de cultivo impiden una comparación directa de magnitudes.

Finalmente, respecto al quinto objetivo específico, el pronóstico para 2025 reprodujo el patrón estacional histórico de la producción de limón. Los mayores valores puntuales se estimaron entre enero y abril, alcanzando el máximo en marzo con 36.81 , mientras que posteriormente se proyectó una disminución hasta septiembre, con un mínimo de 21.03 , seguida de una recuperación hacia diciembre, cuando el pronóstico alcanzó 30.28 . Los intervalos de predicción al 80% y 95% reflejan la incertidumbre asociada a cada estimación mensual. Este comportamiento es coherente con Bhuyan et al. (2025), quienes mostraron que los pronósticos agrícolas mantienen trayectorias estructuradas acompañadas de intervalos de confianza, y con Thapa et al. (2022), quienes señalaron la utilidad de los modelos ARIMA para apoyar la planificación sectorial. En este sentido,

las proyecciones obtenidas constituyen una referencia cuantitativa de corto plazo, que debe interpretarse conjuntamente con factores climáticos, productivos y de mercado no incorporados explícitamente en el modelo univariado.

CAPÍTULO IV. CONCLUSIONES

En relación con el objetivo general, se estimó un modelo de series de tiempo mediante la metodología Box–Jenkins para pronosticar la producción mensual de limón en el Perú durante el periodo 2010–2025. Entre los modelos cuyos coeficientes resultaron estadísticamente significativos al 5 %, se seleccionó el SARIMA (1,0,0) (0,1,1)₁₂ con deriva, al presentar AIC = 817.4497, AICc = 817.6951 y BIC = 829.9456, los menores valores entre las especificaciones válidas evaluadas.

En relación con el primer objetivo específico, se determinó que la producción mensual de limón presenta una marcada estacionalidad anual y cambios en su nivel a lo largo del periodo analizado. La descomposición STL permitió identificar una disminución importante alrededor de 2017–2018 y una recuperación posterior, mientras que la ACF mostró autocorrelaciones relevantes en los primeros rezagos y en múltiplos de doce.

Respecto al segundo objetivo específico, se comprobó que para alcanzar las condiciones requeridas de estacionariedad no fue necesario aplicar una transformación logarítmica ni diferenciación regular. La identificación determinó $d = 0$ y $D = 1$, por lo que se aplicó únicamente una diferenciación estacional de primer orden. La serie resultante obtuvo ADF = -3.4784 con $p = 0.0466$, Phillips–Perron = -45.5055 con $p = 0.0100$ y KPSS = 0.1394 con $p = 0.1000$.

En cuanto al tercer objetivo específico, el modelo final SARIMA (1,0,0) (0,1,1)₁₂ con deriva estuvo conformado por $ar_1 = 0.7542$, $sma_1 = -0.8550$ y deriva = 0.0670, todos estadísticamente significativos con $p < 0.001$. Los intervalos de confianza al 95 % no incluyeron el valor cero para ninguno de los parámetros.

Con respecto al cuarto objetivo específico, la validación confirmó un comportamiento residual adecuado y una capacidad predictiva razonable fuera de muestra. La prueba de Ljung–

Box obtuvo $Q = 24.172$ y $p = 0.3383$, sin evidencia de autocorrelación residual, mientras que Lilliefors presentó $D = 0.0638$ y $p = 0.0712$, por lo que no se rechazó la normalidad. En el conjunto de prueba se obtuvo $RMSE = 3.9233$, $MAE = 3.4243$, $MAPE = 10.9476 \%$ y $MASE = 0.9704$.

Finalmente, respecto al quinto objetivo específico, el pronóstico mensual para 2025 mantuvo el patrón estacional observado históricamente. El mayor valor puntual se estimó para marzo con 36.81, seguido de febrero con 35.28 y abril con 35.19; posteriormente se proyectó una disminución hasta septiembre, con 21.03, y una recuperación entre octubre y diciembre, alcanzando 30.28 al cierre del año. Los intervalos de predicción al 80 % y 95 % permiten expresar la incertidumbre asociada a las estimaciones, por lo que las proyecciones constituyen una referencia cuantitativa para la planificación de corto plazo de la producción de limón en el Perú.

CAPÍTULO V. RECOMENDACIONES

Se sugiere que en investigaciones futuras se compare la metodología empleada con redes neuronales u otros métodos de pronóstico. También sería adecuado explorar otras transformaciones además de la logarítmica para series con outliers o cambios de varianza, con el objetivo de optimizar su preparación previa a la modelación.

Se sugiere continuar utilizando la metodología Box–Jenkins en futuros trabajos de producción agrícola, incluyendo variables exógenas relacionadas con clima, precios, disponibilidad de agua o eventos fitosanitarios, con el fin de mejorar la capacidad explicativa del modelo estimado. De igual forma, es conveniente actualizar periódicamente la serie con nuevos datos mensuales, a fin de reevaluar la estabilidad paramétrica del modelo seleccionado y verificar si continúa siendo la alternativa más parsimoniosa y eficiente para el pronóstico de la producción de limón en el Perú.

Finalmente, se recomienda utilizar los pronósticos mensuales del año 2025 como insumo para la planificación agrícola, comercial y logística, articulándolos con información contextual sobre estacionalidad de cosecha, comportamiento de precios y disponibilidad de recursos productivos. Sería provechoso, a la vez, convertir de forma sistemática las predicciones e intervalos de confianza en escenarios operativos de decisión, de manera que productores, comercializadores e instituciones del sector anticipen mejores periodos de mayor y menor oferta de limón en el Perú.

REFERENCIAS

- Acosta Bravo, R. E., & Chapoñan Bances, D. Y. (2022). *Modelo de Series de Tiempo para describir la produccion mensual de espárrago en el Perú, periodo enero 2027 - diciembre 2018*. [Tesis de Licenciatura], Universidad Nacional Pedro Ruiz Gallo, Chiclayo. Obtenido de <https://repositorio.unprg.edu.pe/handle/20.500.12893/10670>
- Agraria. (2025). Peruvian lemon export outlook: 2024 results and perspectives [Tridge]. *Agraria.pe*. <https://www.tridge.com/news/peruvian-lemon-export-outlook-mfsjgy>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723. <https://doi.org/10.1109/TAC.1974.1100705>
- Banco Central de Reserva del Perú. (2025). *Agrícola—Limón (Serie PN01788AM)* (No. PN01788AM) [Dataset]. <https://estadisticas.bcrp.gob.pe/estadisticas/series/mensuales/resultados/PN01788AM/html>
- Bhuyan, N., Mahanta, S., & Sarma, D. (2025). Forecasting Yield of Major Crops in Assam: A Time Series Approach. *Journal of Scientific Research and Reports*, 31(6), 932-942. <https://doi.org/10.9734/jsrr/2025/v31i63187>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time Series Analysis* (1.^a ed.). Wiley. <https://doi.org/10.1002/9781118619193>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time series analysis: Forecasting and control* (Fifth edition). Wiley.
- Castillo-Coronado, Y. D. M., Montes Ninaquispe, J. C., Chavesta Paico, S. J., Carbonel Mendoza, J. L., Vasquez Huatay, K. C., Portilla Sampen, J. E., & Zegarra Escudero, H. T. (2025). Commercial Dynamism of Peru's Citrus Fruit Exports: An Analysis of Their Destination

- Markets. *Proceedings of the 23rd LACCEI International Multi-Conference for Engineering, Education and Technology (LACCEI): «Engineering, Artificial Intelligence, and Sustainable Technologies in service of society»*. 23rd LACCEI International Multi-Conference for Engineering, Education and Technology (LACCEI): «Engineering, Artificial Intelligence, and Sustainable Technologies in service of society». <https://doi.org/10.18687/LACCEI2025.1.1.1379>
- Chávez, M., Chavez, I., Torres, E., Atoche, S., Palacios, S., Ramón Trelles Pozo, L., Saavedra Navarro, Y., Nicolas Aldana Yarleque, C., Mendoza, G., & Chuquihuanca Yacsahuanca, N. (2022). *Detection of Outliers in The Peruvian Fruit Production Time Series Using Arima Models*. Intelligent Human Systems Integration (IHSI 2022) Integrating People and Intelligent Systems. <https://doi.org/10.54941/ahfe1001008>
- Crenna, E., Hischier, R., Defraeye, T., & Onwude, D. (2026). Ecological hotspots across the global citrus supply chain: A comprehensive life cycle assessment. *Environmental Challenges*, 22, 101396. <https://doi.org/10.1016/j.envc.2025.101396>
- Dodge, Y. (2008). Kolmogorov–Smirnov Test. En *The Concise Encyclopedia of Statistics* (pp. 283-287). Springer New York. https://doi.org/10.1007/978-0-387-32833-1_214
- Dong, Z., Chen, M., Srivastava, A. K., Mahmood, U. H., Ishfaq, M., Shi, X., Zhang, Y., Moussa, M. G., Li, X., Hu, C., & Zhang, F. (2024). Climate changes altered the citrus fruit quality: A 9-year case study in China. *Science of The Total Environment*, 923, 171406. <https://doi.org/10.1016/j.scitotenv.2024.171406>
- Elakkiya, N., Bhattacharyya, B., & Sathees, K. (2024). Autoregressive Integrated Moving Average (ARIMA) Model with Genetic Algorithm to Forecast the Chilli and Turmeric Productions

- in India. *Journal of Scientific Research and Reports*, 30(6), 127-135.
<https://doi.org/10.9734/jsrr/2024/v30i62027>
- Hernández, R., & Mendoza, C. (2018). Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta. *Revista Universitaria Digital de Ciencias Sociales (RUDICS)*, 714.
- Kasthuri, V., & Selvakumar, S. (2021). Forecasting Foodgrains Production Using Arima Model and Neural Network. *American Journal of Neural Networks and Applications*, 7(2), 30.
<https://doi.org/10.11648/j.ajnna.20210702.12>
- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of Econometrics*, 54(1-3), 159-178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Liu, Q., Charleston, M. A., Richards, S. A., & Holland, B. R. (2023). Performance of Akaike Information Criterion and Bayesian Information Criterion in Selecting Partition Models and Mixture Models. *Systematic Biology*, 72(1), 92-105.
<https://doi.org/10.1093/sysbio/syac081>
- Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303. <https://doi.org/10.1093/biomet/65.2.297>
- Mercado, W., Guadalupe, K., & Vega Alegre, K. (2023). Possible economic losses on the oranges production chain of Peru due to introduction of Huanglongbing (HLB): Simulation of prospective scenarios to 2045. *Scientia Agropecuaria*, 14(4), 419-434.
<https://doi.org/10.17268/sci.agropecu.2023.036>
- Naciones Unidas. (2022). *Informe de los Objetivos de Desarrollo Sostenible 2022*. United Nations Department of Economic and Social Affairs.

- Okorie, I. E., Afuecheta, E., & Nadarajah, S. (2023). Time series and power law analysis of crop yield in some east African countries. *PLOS ONE*, 18(6), e0287011. <https://doi.org/10.1371/journal.pone.0287011>
- Pandit, P., Sagar, A., Ghose, B., Dey, P., Paul, M., Alqadhi, S., Mallick, J., Almohamad, H., & Abdo, H. G. (2023). Hybrid time series models with exogenous variable for improved yield forecasting of major Rabi crops in India. *Scientific Reports*, 13(1), 22240. <https://doi.org/10.1038/s41598-023-49544-w>
- Phillips, P. C. B., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335-346. <https://doi.org/10.1093/biomet/75.2.335>
- Pokhrel, A., & Adhikari, R. (2023). Leveraging Exogenous Insights: A Comparative Forecast of Paddy Production in Nepal Using ARIMA and ARIMAX Models. *Economic Review of Nepal*, 6(1), 52-69. <https://doi.org/10.3126/ern.v6i1.67970>
- Rasera, J. B., Da Silva, R. F., Mourão Filho, F. D. A. A., Delbem, A. C. B., Saraiva, A. M., Sentelhas, P. C., & Marques, P. A. A. (2023). Climate Change and Citriculture: A Bibliometric Analysis. *Agronomy*, 13(3), 723. <https://doi.org/10.3390/agronomy13030723>
- Thapa, R., Devkota, S., Subedi, S., & Jamshidi, B. (2022). Forecasting Area, Production and Productivity of Vegetable Crops in Nepal using the Box-Jenkins ARIMA Model. *Turkish Journal of Agriculture - Food Science and Technology*, 10(2), 174-181. <https://doi.org/10.24925/turjaf.v10i2.174-181.4618>
- USDA Foreign Agricultural Service. (2024). World lemon/lime production, 2023/24 season. In Citrus: World markets and trade. *Special report*. <https://citrusindustry.net/2024/02/22/world-lemon-lime-production/>

Wertenbroch, K., & Skiera, B. (2002). Measuring Consumers' Willingness to Pay at the Point of Purchase. *Journal of Marketing Research*, 39(2), 228-241.

<https://doi.org/10.1509/jmkr.39.2.228.19086>

Zulfiqar, H., Ahmad, R., & Shahzad, U. (2024). Hybrid ARIMA-IIS Approach for Wheat Yield Forecasting: An Integrated Approach. *iRASD Journal of Economics*, 6(1), 109-127.

<https://doi.org/10.52131/joe.2024.0601.0197>

ANEXOS

Anexo 1. Script de R

```
#####  
# MODELO SARIMA - METODOLOGÍA BOX-JENKINS  
# Producción de limón en el Perú (2010-2025)  
#####  
  
# =====  
# 0. LIBRERÍAS  
# =====  
library(readxl)  
library(forecast)  
library(tseries)  
library(ggplot2)  
library(nortest)  
library(knitr)  
  
# =====  
# 1. CARGA DE DATOS  
# =====  
  
datos <- read_excel("BoxJenkins.xlsx")  
  
serie <- ts(datos$pa,  
            start = c(min(datos$year), min(datos$month)),  
            frequency = 12)  
  
# Serie usada para modelar  
serie_modelo <- serie  
  
# =====  
# 2. EXPLORACIÓN DE LA SERIE  
# =====  
autoplot(serie) +  
  ggtitle("Serie original de producción de limón en el Perú")  
  
ggAcf(serie, lag.max = 36) +  
  ggtitle("ACF de la serie original")  
  
ggPacf(serie, lag.max = 36) +  
  ggtitle("PACF de la serie original")  
  
# Descomposición STL  
descomp <- stl(serie, s.window = "periodic")  
autoplot(descomp) + ggtitle("Descomposición STL de la serie original")  
  
# =====  
# 3. ESTACIONARIEDAD DE LA SERIE ORIGINAL  
# =====  
cat("\n=====\n")  
cat("PRUEBAS DE ESTACIONARIEDAD - SERIE ORIGINAL\n")  
cat("=====\n")  
print(adf.test(serie))
```

```

print(pp.test(serie))

# =====
# SIN TRANSFORMACIÓN
# =====
# En esta versión la modelación se realiza directamente sobre
# la producción observada, conservando la escala original.

boxplot(serie ~ cycle(serie),
        main = "Boxplot mensual de la producción",
        xlab = "Mes", ylab = "Producción",
        names =
c("Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct", "Nov", "Dic"))

# =====
# 4. DIFERENCIACIÓN NECESARIA PARA ESTACIONARIEDAD
# =====
# auto.arima se utiliza inicialmente para identificar d y D.
# La búsqueda posterior mantiene esos órdenes de diferenciación
# y compara múltiples estructuras AR y MA.

modelo_guia <- auto.arima(
  serie_modelo,
  seasonal = TRUE,
  stepwise = FALSE,
  approximation = FALSE,
  test = "kpss",
  seasonal.test = "seas",
  ic = "aicc"
)

orden_guia <- arimaorder(modelo_guia)
d_auto <- orden_guia[2]
D_auto <- orden_guia[5]

cat("\n\n=====\n")
cat("MODELO GUÍA DE AUTO.ARIMA\n")
cat("=====\n")
print(modelo_guia)
cat("d seleccionado:", d_auto, "\n")
cat("D seleccionado:", D_auto, "\n")

# Construcción de la serie estacionaria para comprobación visual y formal
serie_estacionaria <- serie_modelo
if (D_auto > 0) {
  for (i in seq_len(D_auto)) {
    serie_estacionaria <- diff(serie_estacionaria, lag =
frequency(serie_modelo))
  }
}
if (d_auto > 0) {
  for (i in seq_len(d_auto)) {
    serie_estacionaria <- diff(serie_estacionaria)
  }
}

# Eliminar NA generados por diferenciación

```

```

serie_estacionaria <- na.omit(serie_estacionaria)

autoplot(serie_estacionaria) +
  ggtitle("Serie final estacionaria")

ggAcf(serie_estacionaria, lag.max = 36) +
  ggtitle("ACF de la serie estacionaria")

ggPacf(serie_estacionaria, lag.max = 36) +
  ggtitle("PACF de la serie estacionaria")

cat("\n=====\\n")
cat("PRUEBAS DE ESTACIONARIEDAD - SERIE FINAL\\n")
cat("=====\\n")
adf_final <- adf.test(serie_estacionaria)
kpss_final <- kpss.test(serie_estacionaria)
pp_final <- pp.test(serie_estacionaria)
print(adf_final)
print(kpss_final)
print(pp_final)

# Criterio conjunto informativo:
# ADF y PP: se desea p < 0.05
# KPSS:      se desea p > 0.05
cumple_estacionariedad <-
  (adf_final$p.value < 0.05) &&
  (kpss_final$p.value > 0.05) &&
  (pp_final$p.value < 0.05)

cat("\n¿Cumple criterio conjunto de estacionariedad?: ",
    ifelse(cumple_estacionariedad, "SI", "REVISAR"), "\\n", sep = "")

# =====
# 5. FUNCIÓN PARA SIGNIFICANCIA DE COEFICIENTES
# =====

extraer_coef <- function(modelo, nombre = "modelo") {
  b <- coef(modelo)
  se <- sqrt(diag(vcov(modelo)))
  z <- b / se
  p <- 2 * (1 - pnorm(abs(z)))

  data.frame(
    Modelo = nombre,
    Parametro = names(b),
    Estimacion = as.numeric(b),
    Error = as.numeric(se),
    Z = as.numeric(z),
    p_value = as.numeric(p),
    Significativo = p < 0.05,
    row.names = NULL
  )
}

coeficientes_significativos <- function(modelo, alpha = 0.05) {
  b <- coef(modelo)
  if (length(b) == 0) return(TRUE)

```

```

se <- sqrt(diag(vcov(modelo)))
if (length(se) != length(b) || any(!is.finite(se)) || any(se <= 0)) {
  return(FALSE)
}

z <- b / se
p <- 2 * (1 - pnorm(abs(z)))
all(is.finite(p)) && all(p < alpha)
}

# =====
# 6. BÚSQUEDA DE MODELOS SARIMA
# =====
# auto.arima ya determinó d y D. Ahora se prueban combinaciones
# de p, q, P y Q, manteniendo únicamente modelos cuyos
# coeficientes sean todos significativos al 5%.
#
# Límites moderados para evitar modelos excesivamente complejos.
max_p <- 5
max_q <- 5
max_P <- 2
max_Q <- 2

resultados <- list()
modelos_validos <- list()
contador <- 1

for (p in 0:max_p) {
  for (q in 0:max_q) {
    for (P in 0:max_P) {
      for (Q in 0:max_Q) {

        # Se evita el modelo sin ningún término AR/MA.
        if ((p + q + P + Q) == 0) next

        ajuste <- tryCatch(
          Arima(
            serie_modelo,
            order = c(p, d_auto, q),
            seasonal = list(order = c(P, D_auto, Q), period = 12),
            include.constant = TRUE,
            method = "ML"
          ),
          error = function(e) NULL,
          warning = function(w) {
            tryCatch(
              suppressWarnings(
                Arima(
                  serie_modelo,
                  order = c(p, d_auto, q),
                  seasonal = list(order = c(P, D_auto, Q), period = 12),
                  include.constant = TRUE,
                  method = "ML"
                )
              ),
              error = function(e) NULL
            )
          }
        )
      }
    }
  }
}

```

```

    }
  )

  if (is.null(ajuste)) next

  sig <- coeficientes_significativos(ajuste, alpha = 0.05)
  nombre <- sprintf("SARIMA(%d,%d,%d) (%d,%d,%d) [12]",
                    p, d_auto, q, P, D_auto, Q)

  resultados[[contador]] <- data.frame(
    Modelo = nombre,
    p = p, d = d_auto, q = q,
    P = P, D = D_auto, Q = Q,
    AIC = AIC(ajuste),
    AICc = ajuste$aicc,
    BIC = BIC(ajuste),
    Todos_significativos = sig,
    stringsAsFactors = FALSE
  )

  if (sig) modelos_validos[[nombre]] <- ajuste
  contador <- contador + 1
}
}
}
}

tabla_modelos <- do.call(rbind, resultados)
tabla_modelos <- tabla_modelos[order(tabla_modelos$AICc), ]
row.names(tabla_modelos) <- NULL

cat("\n\n=====\\n")
cat("TODOS LOS MODELOS EVALUADOS\\n")
cat("=====\\n")
print(tabla_modelos)

# Solo modelos con todos los coeficientes significativos
tabla_significativos <- subset(tabla_modelos, Todos_significativos)
tabla_significativos <-
tabla_significativos[order(tabla_significativos$AICc), ]
row.names(tabla_significativos) <- NULL

cat("\n\n=====\\n")
cat("MODELOS CON TODOS LOS COEFICIENTES SIGNIFICATIVOS (p < 0.05)\\n")
cat("=====\\n")
print(tabla_significativos)

if (nrow(tabla_significativos) == 0) {
  stop("No se encontró ningún modelo dentro de la rejilla con todos los
coeficientes significativos. Amplíe max_p, max_q, max_P o max_Q, o revise la
diferenciación.")
}

# Mostrar los 10 mejores candidatos válidos
cat("\n\n=====\\n")
cat("10 MEJORES MODELOS SIGNIFICATIVOS SEGÚN AICc\\n")
cat("=====\\n")

```

```

print(head(tabla_significativos, 10))

# =====
# 7. SELECCIÓN DEL MODELO FINAL
# =====
mejor_modelo_nombre <- tabla_significativos$Modelo[1]
modelo_final <- modelos_validos[[mejor_modelo_nombre]]

cat("\n=====\\n")
cat("MODELO FINAL SELECCIONADO\\n")
cat("=====\\n")
cat(mejor_modelo_nombre, "\\n")
print(summary(modelo_final))

# Coeficientes del modelo final
tabla_coef_final <- extraer_coef(modelo_final, mejor_modelo_nombre)
print(tabla_coef_final)

# Intervalos de confianza
cat("\nINTERVALOS DE CONFIANZA DE LOS COEFICIENTES\\n")
print(confint(modelo_final))

# =====
# 8. DIAGNÓSTICO DEL MODELO FINAL
# =====
res <- residuals(modelo_final)

autoplot(res) +
  ggtitle("Residuos del modelo final en el tiempo")

ggAcf(res, lag.max = 36) +
  ggtitle("ACF de los residuos")

# Ljung-Box. fitdf descuenta el número de parámetros AR/MA.
ord_final <- arimaorder(modelo_final)
fitdf_final <- ord_final[1] + ord_final[3] + ord_final[4] + ord_final[6]
lag_lb <- max(24, 2 * frequency(serie_modelo))
lag_lb <- min(lag_lb, floor(length(res) / 5))

ljung <- Box.test(
  na.omit(res),
  lag = lag_lb,
  type = "Ljung-Box",
  fitdf = fitdf_final
)
print(ljung)

hist(na.omit(res),
  main = "Histograma de residuos",
  xlab = "Residuos")

qqnorm(na.omit(res))
qqline(na.omit(res))

# Normalidad de residuos (Lilliefors)
print(lillie.test(na.omit(res)))

```

```

# =====
# 9. VALIDACIÓN 2024-2025
# =====
train <- window(serie_modelo, end = c(2023, 12))
test  <- window(serie_modelo, start = c(2024, 1))

ord <- arimaorder(modelo_final)
modelo_val <- Arima(
  train,
  order = ord[1:3],
  seasonal = list(order = ord[4:6], period = 12),
  include.constant = TRUE,
  method = "ML"
)

fc_test <- forecast(modelo_val, h = length(test))
print(accuracy(fc_test, test))

autoplot(fc_test) +
  autolayer(test, series = "Real") +
  ggtitle("Validación del modelo final")

# =====
# 10. PRONÓSTICO FINAL A 12 MESES
# =====
fc_final <- forecast(modelo_final, h = 12, level = c(80, 95))
print(fc_final)

autoplot(serie) +
  autolayer(fitted(modelo_final), series = "Ajuste") +
  autolayer(fc_final$mean, series = "Pronóstico") +
  autolayer(fc_final$lower[,2], linetype = "dashed", series = "LI 95%") +
  autolayer(fc_final$upper[,2], linetype = "dashed", series = "LS 95%") +
  ggtitle("Producción de limón: serie, ajuste y pronóstico") +
  ylab("Producción") + xlab("Año")

tabla_pronostico <- data.frame(
  Periodo = time(fc_final$mean), Pronostico = as.numeric(fc_final$mean),
  LI_80 = as.numeric(fc_final$lower[,1]), LS_80 =
as.numeric(fc_final$upper[,1]),
  LI_95 = as.numeric(fc_final$lower[,2]), LS_95 =
as.numeric(fc_final$upper[,2]))
print(tabla_pronostico)

#####
# FIN DEL SCRIPT
#####

```