



Religación
Press

Frank Alexander Amaya Paiva, Lucía Milagros Farfán Morales,
Diego Henrí Ojeda Alberca, Walter Gastón Alva Alva,
Luis Alberto Calderón Pinedo

LA PROPIEDAD EN CIFRAS

*Pronósticos estadísticos para la
formalización urbana en Piura*



Frank Alexander Amaya Paiva, Lucia Milagros Farfan Morales, Diego Henri
Ojeda Alberca, Walter Gastón Alva Alva, Luis Alberto Calderón Pinedo

La propiedad en cifras
*pronósticos estadísticos para la
formalización urbana en Piura*

Religación Press
[Ideas desde el Sur Global]

*Property in figures.
Statistical forecasts for urban formalization in Piura*

*A propriedade em números.
Previsões estatísticas para a formalização urbana em Piura*

Religación Press

[Ideas desde el Sur Global]

Equipo Editorial

Editorial team

Ana B. Benalcázar

Editora Jefe / Editor in Chief

Felipe Carrión

Director de Comunicación / Scientific Communication Director

Melissa Díaz

Coordinadora Editorial / Editorial Coordinator

Sarahí Licango Rojas

Asistente Editorial / Editorial Assistant

Consejo Editorial

Editorial Board

Jean-Arsène Yao

Dilrabo Keldiyorovna Bakhronova

Fabiana Parra

Mateus Gamba Torres

Siti Mistima Maat

Nikoleta Zampaki

Silvina Sosa

Victor Ancajima Miñán

.....

Religación Press, es parte del fondo editorial del Centro de Investigaciones
CICSHAL-RELIGACIÓN | Religación Press, is part of the editorial collection of the
CICSHAL-RELIGACIÓN Research Center |

Diseño, diagramación y portada | Design, layout and cover: Religación Press.

CP 170515, Quito, Ecuador. América del Sur.

Correo electrónico | E-mail: press@religacion.com

www.religacion.com

Disponible para su descarga gratuita en | Available for free download at

<https://press.religacion.com>

Este título se publica bajo una licencia de Atribución 4.0 Internacional (CC BY 4.0)

This title is published under an Attribution 4.0 International (CC BY 4.0) license.



El presente libro tienen el aval del Centro de Investigaciones en Ciencias y Humanidades desde América Latina - CICS HAL.



Título: La propiedad en cifras. Pronósticos estadísticos para la formalización urbana en Piura

Derechos de autor | Copyright: Frank Alexander Amaya Paiva, Lucia Milagros Farfan Morales, Diego Henrri Ojeda Alberca, Walter Gastón Alva Alva, Luis Alberto Calderón Pinedo

Primera Edición | First Edition: 2026

Editorial | Publisher: Religación Press

Materia Dewey | Dewey Subject: 333 - Economía de la tierra y de la energía

Clasificación Thema | Thema Subject Categories: JBSD - Comunidades urbanas | JBFD - Vivienda y desamparo | PBT - Probabilidad y estadística

BISAC: BUS069030

Público objetivo | Target audience: Profesional / Académico | Professional / Academic

Colección | Collection: Economía

Soportal Format: PDF / Digital

Publicación | Publication date: 2026-09-01

ISBN: 978-9907-845-09-9

Nota obra derivada: El libro retoma y amplía, mediante el trabajo colaborativo de un grupo de investigadores, los hallazgos y aportes presentados en la tesis original: "Pronóstico de títulos de propiedad entregados en la provincia de Piura, basados en el modelo Holt-Winters y la metodología de Box-Jenkins para el período 2024-2025" presentada ante la Universidad Nacional de Piura (Perú) por Frank Alexander Amaya Paiva y Lucia Milagros Farfan Morales, en 2025.

Note: The book takes up and expands, through the collaborative work of a group of researchers, the findings and contributions presented in the original dissertation: "Pronóstico de títulos de propiedad entregados en la provincia de Piura, basados en el modelo Holt-Winters y la metodología de Box-Jenkins para el período 2024-2025" presented to the Universidad Nacional de Piura (Perú) by Frank Alexander Amaya Paiva y Lucia Milagros Farfan Morales in 2025.

[APA 7]

Amaya Paiva, F. A., Farfan Morales, L. M., Ojeda Alberca, D. H., Alva Alva, W. G., & Calderón Pinedo, L. A. (2026). *La propiedad en cifras. Pronósticos estadísticos para la formalización urbana en Piura*. Religación Press. <https://doi.org/10.46652/ReligacionPress.484>

Revisión por pares

El presente libro constituye el resultado de un riguroso proceso de investigación académica, cuya calidad metodológica y solidez argumental han sido validadas mediante un sistema de revisión por pares externos implementado bajo el protocolo de doble ciego, bajo la supervisión del Centro de Investigaciones en Ciencias y Humanidades desde América Latina (CICSHAL). Como garantía de transparencia y rigor científico, los informes de evaluación realizados por los especialistas designados se conservan en el archivo institucional de la editorial, a disposición de las instancias que así lo requieran.

Peer Review

This book is the result of a rigorous academic research process, whose methodological quality and argumentative solidity have been validated through an external peer-review system implemented under a double-blind protocol, under the supervision of the Center for Research in Sciences and Humanities from Latin America (CICSHAL). As a guarantee of transparency and scientific rigor, the evaluation reports prepared by the designated specialists are preserved in the publisher's institutional archives, available to any party that may require them.

Sobre los autores

ABOUT THE AUTHORS

Frank Alexander Amaya Paiva

Universidad Nacional de Piura | Piura | Perú

<https://orcid.org/0009-0000-6143-5452>

1342018035@alumnos.unp.edu.pe

frank.amaya.pa.2019.19@gmail.com

Licenciado en Estadística con sólida base matemática y experiencia en ingeniería de datos y modelos estadísticos, utilizando Python, R, SPSS, SQL y entornos Cloud.

Lucia Milagros Farfan Morales

Universidad Nacional de Piura | Piura | Perú

<https://orcid.org/0009-0003-8806-012X>

71624545@posgrado.unp.edu.pe

luciamilagrosfm2022@gmail.com

Licenciada en Estadística, con estudios culminados de Maestría en Ciencias de la Educación, mención en Docencia e Investigación. Profesional responsable, comprometida y con orientación al análisis de datos y la investigación.

Diego Henrri Ojeda Alberca

Universidad Nacional de Piura | Piura | Perú

<https://orcid.org/0009-0002-3704-1829>

75681803@posgrado.unp.edu.pe

diegohenrriojedaalberca@gmail.com

Licenciado en Estadística, manejo de software R, SPSS, Python, SQL, herramientas de inteligencia artificial. Egresado de la Maestría en Ciencia de Datos por la Universidad Autónoma del Perú. Actualmente cursa el Doctorado en Ciencias de la Educación.

Walter Gastón Alva Alva

Universidad Nacional de Piura | Piura | Perú

<https://orcid.org/0000-0002-0091-1416>

walvaa@unp.edu.pe

wgalva@hotmail.com

Doctor en Ciencias de la Educación, Docente de la Facultad de Ciencias, Escuela Profesional de Estadística, profesor nombrado; más de 25 años de experiencia en docencia universitaria y asesor de investigación.

Luis Alberto Calderon Pinedo

Universidad Nacional de Piura | Piura | Perú

<https://orcid.org/0000-0003-2099-5319>

lcalderonp@unp.edu.pe

lcalderonp1008@gmail.com

Ingeniero Electrónico egresado de la Universidad Privada Antenor Orrego de Trujillo, Magister en Ingeniería Informática y Doctorando en Tecnologías de la información y comunicaciones, en la Universidad Nacional de Piura.

Resumen

La formalización de la propiedad en la provincia de Piura enfrenta desafíos significativos debido a la ausencia de herramientas predictivas que permitan una planificación efectiva. Esta investigación aborda esta problemática mediante la aplicación de dos metodologías de pronóstico de series temporales: los modelos de Holt-Winters y la metodología de Box-Jenkins. A través del análisis de la serie histórica de títulos de propiedad entregados entre 2008 y 2023, se identifican patrones estacionales y tendencias que caracterizan el comportamiento de la variable en estudio. El estudio compara ambos enfoques para determinar cuál ofrece mayor precisión predictiva, permitiendo generar proyecciones confiables para el periodo 2024-2025. Los resultados proporcionan a las autoridades municipales una herramienta sólida para anticipar la demanda, optimizar la asignación de recursos y mejorar la gestión del proceso de titulación, contribuyendo así a la seguridad jurídica de las familias piuranas y al desarrollo ordenado del territorio.

Palabras clave:

Pronóstico; series temporales; titulación de propiedades; Holt-Winters; Box-Jenkins.

Abstract

The formalization of property in the province of Piura faces significant challenges due to the absence of predictive tools that enable effective planning. This research addresses this problem through the application of two time series forecasting methodologies: Holt-Winters models and the Box-Jenkins methodology. Through the analysis of the historical series of property titles delivered between 2008 and 2023, seasonal patterns and trends characterizing the behavior of the variable under study are identified. The study compares both approaches to determine which offers greater predictive accuracy, allowing for the generation of reliable projections for the 2024-2025 period. The results provide municipal authorities with a solid tool to anticipate demand, optimize resource allocation, and improve the management of the titling process, thereby contributing to the legal security of families in Piura and the orderly development of the territory.

Keywords:

Forecasting; time series; property titling; Holt-Winters; Box-Jenkins.

Resumo

A formalização da propriedade na província de Piura enfrenta desafios significativos devido à ausência de ferramentas preditivas que permitam um planejamento efetivo. Esta pesquisa aborda essa problemática mediante a aplicação de duas metodologias de previsão de séries temporais: os modelos de Holt-Winters e a metodologia de Box-Jenkins. Através da análise da série histórica de títulos de propriedade entregues entre 2008 e 2023, identificam-se padrões sazonais e tendências que caracterizam o comportamento da variável em estudo. O estudo compara ambas as abordagens para determinar qual oferece maior precisão preditiva, permitindo gerar projeções confiáveis para o período 2024-2025. Os resultados proporcionam às autoridades municipais uma ferramenta sólida para antecipar a demanda, otimizar a alocação de recursos e melhorar a gestão do processo de titulação, contribuindo assim para a segurança jurídica das famílias piuranas e para o desenvolvimento ordenado do território.

Palavras-chave:

Previsão; séries temporais; titulação de propriedades; Holt-Winters; Box-Jenkins.

LA PROPIEDAD EN CIFRAS

Pronósticos estadísticos para la formalización urbana en Piura

CONTENIDO

Revisión por pares	7
Peer Review	7
Sobre los autores	8
About the authors	8
Resumen	10
Abstract	11
Resumo	11
Introducción	16

Capítulo 1 23

El pronóstico de títulos de propiedad en la provincia de Piura. Un enfoque desde los modelos Holt-Winters y Box-Jenkins	23
La formalización de la propiedad como desafío estructural en el Perú contemporáneo	24
Limitaciones institucionales y la necesidad de herramientas predictivas para la planificación urbana	27
Formulación de preguntas de investigación y objetivos orientados a la predicción	31
Justificación multidimensional y pertinencia de la investigación en el contexto local	34
Ámbito geográfico y alcance temporal de la investigación	37

Capítulo 2 41

Fundamentos conceptuales y metodológicos para el pronóstico de títulos de propiedad	41
La evolución de los modelos predictivos en el contexto de la gestión pública y la producción agrícola	42
Aplicaciones nacionales y regionales de los modelos de pronóstico en el Perú	46
Fundamentos conceptuales de la propiedad, la posesión y los documentos que las acreditan	51
Las series temporales y los modelos de pronóstico como herramientas para la planificación	55

Evaluación de modelos predictivos y marco institucional para el pronóstico de títulos de propiedad	76
Criterios y métricas para la evaluación del desempeño predictivo en series temporales	76
Marco institucional y legal para la formalización de la propiedad en la provincia de Piura	79
Glosario de términos básicos y conceptos fundamentales para el análisis de series temporales y formalización de la propiedad	82

Capítulo 3 86

Fundamentos metodológicos para el pronóstico de títulos de propiedad en la provincia de Piura	86
Enfoque cuantitativo y diseño longitudinal para el análisis de series temporales	87
Procedimientos sistemáticos para la recolección, procesamiento y modelización de datos	89
Técnicas de recolección de datos, instrumentos y consideraciones éticas en la investigación	92

Capítulo 4 95

Análisis de resultados y evaluación de modelos predictivos para la entrega de títulos de propiedad	95
Caracterización descriptiva y comportamiento histórico de la serie temporal	96
Descomposición de la serie temporal e identificación de componentes estructurales	98
Optimización y selección del modelo Holt-Winters para el pronóstico de títulos de propiedad	100
Evaluación del modelo Holt-Winters aditivo y selección del modelo multiplicativo óptimo	103
Ajuste del modelo aditivo y verificación de supuestos para la serie de títulos de propiedad	103
Optimización y selección del modelo multiplicativo de Holt-Winters para el pronóstico	106
Evaluación del modelo Holt-Winters multiplicativo y selección del modelo ARIMA óptimo	109
Ajuste del modelo multiplicativo y verificación de supuestos para la serie de títulos de propiedad	109
Identificación y selección de parámetros óptimos para el modelo ARIMA	112
Evaluación y selección final del modelo ARIMA para el pronóstico de títulos de propiedad	115

Validación del modelo ARIMA y propuesta del modelo SARIMA para el pronóstico de títulos de propiedad	118
Validación del modelo ARIMA y verificación de supuestos de normalidad	118
Identificación y selección de parámetros óptimos para el modelo SARIMA	122
Evaluación y selección final del modelo SARIMA para el pronóstico de títulos de propiedad	124
Evaluación y validación del modelo SARIMA para el pronóstico de títulos de propiedad en Piura	130
Validación del modelo SARIMA y verificación de supuestos de normalidad	130
Comparación de modelos y selección del enfoque predictivo óptimo	137
Verificación exhaustiva de los supuestos del modelo SARIMA	141
Generación de pronósticos trimestrales y su utilidad para la planificación estratégica	152
Discusión de resultados en el contexto de investigaciones previas	156
Capítulo 5.	161
Hallazgos fundamentales y proyecciones para la gestión de títulos de propiedad en Piura	161
Síntesis de los resultados obtenidos en la modelización de la serie temporal	162
Superioridad del modelo SARIMA y cumplimiento de supuestos	166
Proyecciones trimestrales y recomendaciones para la gestión pública	169
Referencias	174

Introducción

La problemática de la propiedad ha constituido una constante histórica en diversas latitudes del mundo, configurando una división social que ha perdurado a lo largo de los siglos entre quienes detentan la posesión formal de bienes inmuebles y quienes carecen de dicho reconocimiento jurídico. En el contexto peruano, esta dicotomía adquiere contornos particularmente agudos, evidenciando que más del 50% de los denominados propietarios carecen de un título formal, disponiendo únicamente de certificados de posesión o, en el peor de los casos, de un control temporal sobre el terreno que habitan. Esta realidad refleja una informalidad generalizada que permea las actividades socioeconómicas del país, generando un escenario de medidas improvisadas donde las leyes no logran establecer la visión necesaria para resolver los problemas sociales, especialmente en el ámbito de la propiedad. A pesar de que las municipalidades cuentan con la autoridad para emitir certificados de posesión otorgados por el Estado, en la práctica limitan su entrega a asociaciones específicas o simplemente no lo hacen, perpetuando así un ciclo de informalidad que afecta a millones de familias peruanas.

El derecho a la vivienda, reconocido en el Artículo 25 de la Declaración Universal de Derechos Humanos,

constituye un componente esencial para alcanzar un nivel de vida adecuado que promueva la salud y el bienestar de las familias y los individuos (Gledhill, 2010). Este reconocimiento normativo ha impulsado, en las primeras décadas del siglo XXI, un esfuerzo deliberado por parte del Estado Peruano para avanzar en la formalización de la propiedad inmobiliaria, respondiendo a una realidad apremiante donde numerosos poseedores de inmuebles carecían de un título de propiedad formal, disponiendo únicamente de certificados o documentos privados emitidos por asociaciones vecinales u organizaciones populares. La informalidad no solo afecta la seguridad jurídica de las familias, sino que también limita su acceso a servicios básicos, créditos bancarios y programas sociales, perpetuando ciclos de pobreza y exclusión (De Soto, 2021; Del Castillo et al., 2020; Calderón-Cockburn, 2021). Esta evidencia empírica refuerza la necesidad de políticas públicas orientadas a la formalización como mecanismo de inclusión social y desarrollo territorial.

En este contexto, la Municipalidad Provincial de Piura enfrenta serias limitaciones en la entrega de títulos de propiedad, derivadas principalmente de la ausencia de un sistema planificado que articule los recursos disponibles y optimice la gestión de este proceso. La complejidad, minuciosidad y sensibilidad que caracterizan a la titulación de propiedades exigen un enfoque estratégico que trascienda las urgencias del corto plazo y se proyecte con vi-

sión de mediano y largo alcance. Resulta crucial diseñar un plan estratégico que incorpore un sistema de pronóstico capaz de estimar la cantidad de títulos que podrán ser entregados en los años o periodos venideros, facilitando una planificación efectiva y permitiendo optimizar la asignación de recursos, mejorar los tiempos de respuesta y reducir la incertidumbre en la gestión municipal. La planificación basada en pronósticos confiables ha demostrado ser un factor determinante en la eficiencia de las administraciones públicas en diversos contextos geográficos, permitiendo anticipar escenarios futuros y diseñar intervenciones oportunas (Armstrong, 2020; Hyndman & Athanasopoulos, 2021).

El uso de la estadística, apoyado en diversas herramientas, permite contribuir al desarrollo de previsiones tanto en el corto, mediano y largo plazo. La proyección es una tarea de gran interés, estrechamente relacionada con las actividades humanas, que ha sido durante mucho tiempo una actividad necesaria para prever situaciones desfavorables o mejorar significativamente la toma de decisiones para el bienestar común. En el ámbito de las series temporales, dos metodologías han demostrado particular eficacia para abordar problemas con componentes estacionales y tendencias: los modelos de Holt-Winters y la metodología de Box-Jenkins. El método de Holt-Winters, conocido también como suavizamiento exponencial triple, resulta especialmente útil cuando los datos pre-

sentan tanto tendencia como estacionalidad, permitiendo descomponer la serie en sus componentes fundamentales y proyectar su evolución futura con un nivel aceptable de precisión (Winters, 1960; Gardner, 2019). Por su parte, la metodología Box-Jenkins, representada por los modelos ARIMA y SARIMA, ofrece un enfoque sistemático para identificar, estimar y diagnosticar modelos estadísticos en series temporales, basándose en las propiedades de autocorrelación de los datos (Box et al., 2015; Wei, 2018).

La presente investigación se enmarca en un enfoque cuantitativo, con diseño no experimental y nivel predictivo, de tipo aplicada. La muestra de estudio está conformada por la información de títulos de propiedad entregados por la Municipalidad Provincial de Piura en el período comprendido entre 2008 y 2023, los cuales fueron procesados utilizando aplicaciones estadísticas avanzadas como Python y R. El objetivo general es estimar un modelo para pronosticar la cantidad de títulos de propiedad entregados en la provincia de Piura, utilizando técnicas de Holt-Winters y Box-Jenkins, para el periodo 2024-2025. Para ello, se plantean objetivos específicos que incluyen la identificación de patrones, tendencias, estacionalidad y estacionariedad en la serie temporal; la determinación de los componentes óptimos de los modelos de Holt-Winters; la evaluación de los parámetros óptimos de los modelos de Box-Jenkins; la comparación de ambos enfoques

para seleccionar el de mayor precisión; y la generación de pronósticos trimestrales para el periodo 2024-2025.

La justificación de esta investigación se asienta en múltiples dimensiones. Desde el punto de vista práctico, busca aportar un modelo utilizable por la Subgerencia de Asentamientos Humanos de la Municipalidad Provincial de Piura para mejorar sus pronósticos y, en consecuencia, contribuir a una planificación más efectiva y una mejor toma de decisiones. En el plano social, los resultados serán de gran beneficio para el área de titulación, facilitando el cumplimiento de las metas institucionales y atendiendo las necesidades de las familias piuranas que anhelan la seguridad jurídica que otorga un título de propiedad. En cuanto al aporte teórico, la investigación sistematiza los fundamentos de los modelos de Holt-Winters y la metodología de Box-Jenkins, ofreciendo una aplicación concreta en el contexto de la gestión pública local. Metodológicamente, el estudio detalla los pasos a seguir en el proceso de estimación de los modelos, desde la selección del más adecuado hasta la generación de las estimaciones finales, constituyendo una guía para futuras investigaciones en el ámbito de la predicción de series temporales aplicadas a la administración pública.

La investigación se circunscribe al ámbito geográfico de la provincia de Piura, comprendiendo específicamente los distritos de Piura, Tambogrande, Catacaos, Cura Mori

y 26 de Octubre. La información analizada corresponde a la cantidad de títulos de propiedad emitidos por la Municipalidad Provincial de Piura a través de la Subgerencia de Asentamientos Humanos, abarcando el periodo comprendido entre el primer trimestre del año 2008 y el cuarto trimestre del 2023. Esta serie histórica, que cubre un horizonte de dieciséis años, proporciona una base empírica suficiente para identificar los patrones estacionales y las tendencias de largo plazo que caracterizan la variable en estudio, así como para calibrar y validar los modelos predictivos propuestos. La selección de este periodo de análisis responde a consideraciones de disponibilidad de datos y relevancia temporal, coincidiendo con el inicio de los programas de formalización masiva impulsados por el Estado peruano y cubriendo años de expansión económica y períodos de crisis que han afectado significativamente la dinámica de la titulación de propiedades (Rosas & Morales, 2021; Espinoza & Ríos, 2022).

Capítulo 1

El pronóstico de títulos de propiedad en la provincia de Piura. Un enfoque desde los modelos Holt-Winters y Box-Jenkins

LA PROPIEDAD EN CIFRAS:
pronósticos estadísticos para la formalización urbana en Piura

La formalización de la propiedad como desafío estructural en el Perú contemporáneo

La problemática de la propiedad ha constituido una constante histórica en diversas latitudes del mundo, configurando una división social que ha perdurado a lo largo de los siglos entre quienes detentan la posesión formal de bienes inmuebles y quienes carecen de dicho reconocimiento jurídico. Esta dicotomía se manifiesta en una clara diferenciación entre los propietarios —que incluyen tanto al Estado como a personas naturales o jurídicas debidamente tituladas— y aquellos que habitan en calidad de arrendatarios bajo contratos temporales o, en situaciones más precarias, como ocupantes informales de terrenos ajenos. La persistencia de esta brecha patrimonial ha motivado que organismos internacionales y gobiernos nacionales dirijan su atención hacia la necesidad de garantizar el acceso a una vivienda digna como elemento fundamental para el desarrollo humano y la estabilidad social. En América Latina, esta problemática adquiere contornos particularmente agudos debido a los procesos de urbanización acelerada y migración campo-ciudad que caracterizaron la segunda mitad del siglo XX, generando cinturones de pobreza y asentamientos informales en las periferias de las principales ciudades (Gilbert, 2012; Durand-Lasserve & Selod, 2019). La región ha experimentado transformaciones demográficas profundas que han

tensionado la capacidad de los Estados para responder adecuadamente a la demanda de vivienda formal, lo que ha derivado en la proliferación de ocupaciones irregulares y la consolidación de un mercado paralelo de tierras.

En este contexto, el Artículo 25 de la Declaración Universal de Derechos Humanos establece que el derecho a la vivienda constituye un componente esencial para alcanzar un nivel de vida adecuado que promueva la salud y el bienestar de las familias y los individuos (Gledhill, 2010). Este reconocimiento normativo ha impulsado, en las primeras décadas del siglo XXI, un esfuerzo deliberado por parte del Estado Peruano para avanzar en la formalización de la propiedad inmobiliaria. Dicho esfuerzo respondía a una realidad apremiante: numerosos poseedores de inmuebles carecían de un título de propiedad formal, disponiendo únicamente de certificados o documentos privados emitidos por asociaciones vecinales u organizaciones populares. Esta situación evidenciaba la existencia generalizada de propiedades no formalizadas, centros urbanos no regulados y urbanizaciones populares que crecían al margen de los marcos legales establecidos. La informalidad no solo afectaba la seguridad jurídica de las familias, sino que también limitaba su acceso a servicios básicos, créditos bancarios y programas sociales, perpetuando ciclos de pobreza y exclusión. Investigaciones recientes han documentado que la falta de titulación formal restringe significativamente la capacidad de los hogares

para invertir en mejoras habitacionales y acceder a financiamiento, lo que a su vez profundiza las desigualdades socioeconómicas en contextos urbanos (De Soto, 2021; Del Castillo et al., 2020; Calderón-Cockburn, 2021). Esta evidencia empírica refuerza la necesidad de políticas públicas orientadas a la formalización como mecanismo de inclusión social y desarrollo territorial.

Sin embargo, la demanda social de las familias por acceder a un entorno habitable se enfrenta a una compleja madeja de problemas de naturaleza social, política, económica y legal. Los gobiernos de turno frecuentemente incorporan en sus discursos y programas la promesa de otorgar títulos de propiedad, generando expectativas que no siempre se materializan en acciones concretas. Paralelamente, emerge un fenómeno igualmente preocupante: la aparición de traficantes de terrenos baldíos que, aprovechando el descuido estatal de décadas sobre extensas áreas de propiedad pública, promueven ocupaciones ilegales y comercializan predios sin ningún respaldo jurídico. Este escenario genera un círculo vicioso en el que la informalidad se retroalimenta y profundiza las brechas sociales. La literatura especializada ha señalado que el tráfico de tierras y la ocupación ilegal constituyen manifestaciones de una gobernanza urbana débil, caracterizada por la ausencia de mecanismos efectivos de control territorial y planificación urbana sostenible (Fernandes, 2018; Smolka, 2020; Ioris, 2021). Estos fenómenos no

solo vulneran el derecho a la propiedad, sino que también comprometen la sostenibilidad ambiental y la seguridad de las poblaciones asentadas en zonas de riesgo. La experiencia comparada de países como Brasil, Colombia y México muestra que la regularización de asentamientos informales requiere enfoques integrales que combinen instrumentos legales, programas de mejoramiento barrial y sistemas de monitoreo que permitan anticipar y prevenir la formación de nuevos núcleos de informalidad (Soto et al., 2020; Clichevsky, 2019; Abramo, 2021).

Limitaciones institucionales y la necesidad de herramientas predictivas para la planificación urbana

La Municipalidad Provincial de Piura enfrenta serias limitaciones en la entrega de títulos de propiedad, derivadas principalmente de la ausencia de un sistema planificado que articule los recursos disponibles y optimice la gestión de este proceso. La complejidad, minuciosidad y sensibilidad que caracterizan a la titulación de propiedades exigen un enfoque estratégico que trascienda las urgencias del corto plazo y se proyecte con visión de mediano y largo alcance. En este sentido, resulta crucial diseñar un plan estratégico que incorpore un sistema de pronóstico capaz de estimar la cantidad de títulos que podrán ser entregados en los años o periodos venideros. Un sistema de

estas características facilitaría una planificación efectiva y permitiría optimizar la asignación de recursos, mejorar los tiempos de respuesta y reducir la incertidumbre en la gestión municipal. La planificación basada en pronósticos confiables ha demostrado ser un factor determinante en la eficiencia de las administraciones públicas en diversos contextos geográficos, permitiendo anticipar escenarios futuros y diseñar intervenciones oportunas (Armstrong, 2020; Hyndman & Athanasopoulos, 2021). En el caso específico de la titulación de propiedades, contar con proyecciones precisas permite dimensionar adecuadamente los equipos de trabajo, distribuir los presupuestos anuales y establecer metas realistas que eviten tanto la subestimación como la sobreestimación de la capacidad institucional.

La construcción de pronósticos precisos y confiables requiere la creación de modelos que mejoren la interpretación y el análisis de los datos disponibles. En el ámbito de las series temporales, dos metodologías han demostrado particular eficacia para abordar problemas con componentes estacionales y tendencias: los modelos de Holt-Winters y la metodología de Box-Jenkins. El método de Holt-Winters, conocido también como suavizamiento exponencial triple, resulta especialmente útil cuando los datos presentan tanto tendencia como estacionalidad, permitiendo descomponer la serie en sus componentes fundamentales y proyectar su evolución futura con

un nivel aceptable de precisión. Esta técnica se basa en la aplicación recursiva de ecuaciones de suavizamiento que actualizan continuamente las estimaciones de nivel, tendencia y estacionalidad a medida que se incorporan nuevas observaciones (Winters, 1960; Gardner, 2019). Por su parte, la metodología Box-Jenkins, representada por los modelos ARIMA (Autoregressive Integrated Moving Average), ofrece un enfoque sistemático para identificar, estimar y diagnosticar modelos estadísticos en series temporales, basándose en las propiedades de autocorrelación de los datos. Esta metodología, desarrollada originalmente por George Box y Gwilym Jenkins en la década de 1970, ha sido ampliamente adoptada en campos tan diversos como la economía, la meteorología, la epidemiología y la gestión pública (Box et al., 2015; Wei, 2018). La literatura especializada ha documentado numerosas aplicaciones exitosas de ambos enfoques en la predicción de indicadores de gestión pública, como la demanda de servicios, los ingresos tributarios y la producción de bienes públicos (Maher & Zhang, 2020; Wang et al., 2021; Liu et al., 2022).

Para evaluar el desempeño predictivo de ambos modelos, se emplea comúnmente la raíz del error cuadrático medio (RMSE) o el error porcentual absoluto medio (MAPE). Esta métrica resulta fundamental porque permite cuantificar la precisión de las predicciones realizadas por cada modelo y comparar su capacidad para capturar los patrones subyacentes en los datos. El MAPE, en parti-

cular, ofrece la ventaja de ser independiente de la escala de los datos, lo que facilita la comparación entre diferentes series temporales y contextos de aplicación (Hyndman & Koehler, 2006; Makridakis et al., 2020). Investigaciones comparativas en el ámbito de las series temporales han mostrado que la elección del modelo más adecuado depende en gran medida de las características específicas de los datos, como la presencia de estacionalidad, la magnitud de la tendencia y la longitud de la serie histórica disponible (Petropoulos et al., 2019; Svetunkov et al., 2020). El modelo que presente el menor valor de MAPE será considerado el más adecuado para generar las proyecciones, que en este caso se enfocarán en estimar la cantidad de títulos de propiedad a entregar en la provincia de Piura durante el periodo 2024-2025. La selección del modelo más preciso contribuirá a que las predicciones sean lo más exactas y útiles posible para la toma de decisiones y la planificación territorial en la provincia. Esta aproximación metodológica se alinea con las mejores prácticas en la modelización predictiva para la gestión pública, donde la precisión de los pronósticos incide directamente en la calidad de las políticas implementadas y en la asignación eficiente de los recursos públicos (Bueno et al., 2020; González-Morales et al., 2021).

Formulación de preguntas de investigación y objetivos orientados a la predicción

En correspondencia con la problemática descrita, la investigación se articula en torno a una pregunta general que guía el desarrollo metodológico: ¿Cuál es el modelo más adecuado para pronosticar la cantidad de títulos de propiedad entregados en la provincia de Piura, utilizando las técnicas de Holt-Winters y Box-Jenkins, para el periodo 2024-2025? Este interrogante central enmarca un conjunto de preguntas específicas que orientan el análisis en sus distintas fases y componentes. En primer término, se indaga sobre los patrones, tendencias, estacionalidad y estacionariedad que presenta la serie temporal de los títulos de propiedad entregados entre los años 2008 y 2023, aspectos fundamentales para comprender el comportamiento histórico de la variable en estudio y seleccionar las especificaciones modelísticas más apropiadas. La identificación de estos patrones es crucial porque determina la necesidad de aplicar transformaciones a los datos, como diferenciación o estabilización de la varianza, así como la elección entre modelos aditivos o multiplicativos para el tratamiento de la estacionalidad (Kendall & Ord, 2020; Chatfield, 2019). En el análisis de series temporales, la estacionariedad constituye un requisito fundamental para la aplicación de la metodología Box-Jenkins, ya que los modelos ARIMA se fundamentan en el supuesto de que

los procesos estocásticos que generan los datos son invariantes en el tiempo (Shumway & Stoffer, 2017; Brockwell & Davis, 2016). Por tanto, el examen de la función de autocorrelación y la función de autocorrelación parcial resulta indispensable para determinar el orden de los componentes autorregresivos y de medias móviles que mejor se ajustan a los datos.

Seguidamente, se exploran los componentes óptimos de los modelos de Holt-Winters, que incluyen la determinación de los parámetros de suavizamiento para el nivel, la tendencia y la estacionalidad, así como la elección entre un enfoque aditivo o multiplicativo para la estacionalidad. Esta fase del análisis requiere un proceso iterativo de ajuste y validación que permita identificar la combinación de parámetros que minimice el error de pronóstico dentro de la muestra (Taylor, 2020; Gardner & McKenzie, 2019). Simultáneamente, se investigan los parámetros óptimos de la metodología Box-Jenkins, que involucran la identificación del orden de los componentes autorregresivos (p), el grado de diferenciación (d) necesario para alcanzar la estacionariedad y el orden de los componentes de medias móviles (q). La selección de estos parámetros se basa típicamente en criterios de información como el Akaike Information Criterion (AIC) o el Bayesian Information Criterion (BIC), que balancean la bondad de ajuste con la parsimonia del modelo (Burnham & Anderson, 2019; Schwarz, 1978). La literatura metodológica recomienda

complementar la selección basada en criterios de información con el análisis de los residuos, verificando que estos se comporten como ruido blanco y no presenten patrones sistemáticos que indiquen una especificación inadecuada (Ljung & Box, 2018; McLeod et al., 2019).

Finalmente, se plantea la comparación entre ambos enfoques para determinar cuál proporciona mayor precisión predictiva y, sobre esa base, generar los pronósticos trimestrales para los años 2024 y 2025. Esta comparación se fundamenta en métricas de error que permiten evaluar el desempeño de los modelos tanto en términos de sesgo como de precisión absoluta. La literatura sobre pronósticos ha enfatizado la importancia de utilizar múltiples métricas para obtener una evaluación integral del desempeño predictivo, dado que cada indicador captura aspectos diferentes del error de pronóstico (Armstrong, 2020; Hyndman, 2020). En este sentido, además del MAPE, se recomienda considerar el error medio absoluto (MAE) y el error cuadrático medio (RMSE), que proporcionan información complementaria sobre la distribución de los errores y su sensibilidad a valores atípicos (Willmott & Matsuura, 2019; Chai & Draxler, 2014). La elección final del modelo se orientará hacia aquel que ofrezca un mejor balance entre precisión, estabilidad y parsimonia, garantizando así la utilidad práctica de los pronósticos para la gestión pública. El enfoque adoptado en esta investigación se inscribe en la tradición de estudios aplicados que

buscan transferir conocimientos metodológicos a problemas concretos de la administración pública, contribuyendo a la mejora continua de los procesos de planificación y toma de decisiones en contextos de recursos limitados (Mugambi et al., 2022; Flores & Gómez, 2021; Rojas & Delgado, 2020).

Justificación multidimensional y pertinencia de la investigación en el contexto local

La justificación de esta investigación se asienta en múltiples dimensiones que convergen en su pertinencia y valor agregado. Desde el punto de vista práctico, el estudio busca aportar un modelo utilizable por la Subgerencia de Asentamientos Humanos de la Municipalidad Provincial de Piura para mejorar sus pronósticos y, en consecuencia, contribuir a una planificación más efectiva y una mejor toma de decisiones. La implementación de un sistema de pronóstico basado en metodologías estadísticamente rigurosas podría significar un salto cualitativo en la gestión municipal, reemplazando enfoques intuitivos o basados exclusivamente en la experiencia por aproximaciones cuantitativas que incorporen sistemáticamente la información histórica disponible (Tashman, 2020; Fildes & Goodwin, 2021). En el contexto de la administración pública peruana, donde los recursos son escasos y las demandas sociales son crecientes, disponer de herramientas

predictivas confiables puede marcar la diferencia entre una gestión reactiva y una gestión proactiva, anticipando necesidades y optimizando la asignación de recursos humanos, financieros y materiales. Además, la aplicación de técnicas de pronóstico en el ámbito de la titulación de propiedades podría servir como modelo para otras áreas de la gestión municipal, extendiendo los beneficios de la planificación basada en datos a otros servicios públicos.

En el plano social, los resultados serán de gran beneficio para el área de titulación, facilitando el cumplimiento de las metas institucionales y atendiendo las necesidades de las familias piuranas que anhelan la seguridad jurídica que otorga un título de propiedad. La formalización de la propiedad no solo proporciona certeza legal a los ocupantes, sino que también abre oportunidades de desarrollo económico al permitir el acceso al crédito formal, la inversión en mejoras habitacionales y la participación en los beneficios de los programas sociales del Estado (Federico, 2020; Torero, 2021). Investigaciones realizadas en contextos similares han demostrado que los programas de titulación masiva, cuando están bien diseñados e implementados, pueden generar efectos positivos significativos en el bienestar de los hogares, incluyendo la reducción de la pobreza, la mejora de las condiciones de salud y la integración social de las comunidades beneficiarias (Deininger & Feder, 2021; Muñoz & Valverde, 2022). En este sentido, la investigación trasciende el ámbito puramente

académico para incidir directamente en la calidad de vida de la población piurana, contribuyendo a la construcción de una ciudad más equitativa y organizada territorialmente.

En cuanto al aporte teórico, la investigación sistematiza los fundamentos de los modelos de Holt-Winters y la metodología de Box-Jenkins, ofreciendo una aplicación concreta en el contexto de la gestión pública local. Esta sistematización contribuye a la literatura existente al proporcionar evidencia empírica sobre el desempeño comparativo de ambas metodologías en un ámbito de aplicación poco explorado, como es la predicción de títulos de propiedad. La literatura sobre pronósticos en la gestión pública se ha centrado predominantemente en sectores como la economía, el transporte o la energía, dejando un espacio significativo para investigaciones que aborden servicios sociales específicos como la titulación de viviendas (Alvarado et al., 2021; Herrera & Zambrano, 2022). Metodológicamente, el estudio detalla los pasos a seguir en el proceso de estimación de los modelos, desde la selección del más adecuado hasta la generación de las estimaciones finales, constituyendo una guía para futuras investigaciones en el ámbito de la predicción de series temporales aplicadas a la administración pública. Este componente metodológico es particularmente valioso en contextos donde existe una brecha entre el desarrollo teórico de las técnicas de pronóstico y su aplicación efecti-

va en las instituciones públicas, un fenómeno común en países de renta media como el Perú (Martínez & Ferrada, 2020; Rodríguez & Pérez, 2021).

Ámbito geográfico y alcance temporal de la investigación

La investigación se circunscribe al ámbito geográfico de la provincia de Piura, comprendiendo específicamente los distritos de Piura, Tambogrande, Catacaos, Cura Mori y 26 de Octubre. Esta delimitación responde a criterios de accesibilidad a la información y representatividad territorial, ya que estos distritos concentran la mayor parte de la demanda de titulación de propiedades en la provincia y cuentan con registros sistemáticos de las entregas realizadas por la Municipalidad Provincial. La elección de esta zona de estudio no es arbitraria, sino que responde a la identificación de un problema público concreto y acotado, que permite un análisis en profundidad y la generación de resultados aplicables directamente a la gestión local (Rodríguez & Vásquez, 2020; Sánchez et al., 2021). La provincia de Piura presenta características socioeconómicas y demográficas que la convierten en un caso particularmente relevante para el estudio de la formalización de la propiedad, dado su papel como centro urbano de importancia regional y su histórica condición de polo de atracción migratoria proveniente de las zonas

rurales y andinas de la región. Este dinamismo poblacional ha generado tensiones significativas en el mercado de suelo urbano, exacerbando la informalidad y la ocupación irregular de terrenos (Aguirre & Mendoza, 2022; Ponce & Torres, 2020; Zevallos & Rojas, 2021).

La información analizada corresponde a la cantidad de títulos de propiedad emitidos por la Municipalidad Provincial de Piura a través de la Subgerencia de Asentamientos Humanos, abarcando el periodo comprendido entre el primer trimestre del año 2008 y el cuarto trimestre del 2023. Esta serie histórica, que cubre un horizonte de dieciséis años, proporciona una base empírica suficiente para identificar los patrones estacionales y las tendencias de largo plazo que caracterizan la variable en estudio, así como para calibrar y validar los modelos predictivos propuestos. La selección de este periodo de análisis responde a consideraciones de disponibilidad de datos y relevancia temporal, ya que coincide con el inicio de los programas de formalización masiva impulsados por el Estado peruano y cubre años de expansión económica y períodos de crisis que han afectado significativamente la dinámica de la titulación de propiedades (Rosas & Morales, 2021; Espinoza & Ríos, 2022). Esta amplitud temporal permitirá estimar y desarrollar el modelo predictivo con un nivel adecuado de confianza, a partir del cual se realizarán los pronósticos para los años 2024 y 2025, con un horizonte de predicción de dos años que resulta operativamen-

te relevante para la planificación municipal. La duración prevista para el desarrollo del estudio es de cuatro meses, tiempo durante el cual los investigadores asumirán la totalidad de los costos financieros derivados de la ejecución del proyecto, compromiso que refleja el interés y la responsabilidad con que se aborda la temática investigada.

Capítulo 2

*Fundamentos conceptuales y metodológicos para el
pronóstico de títulos de propiedad*

LA PROPIEDAD EN CIFRAS:
pronósticos estadísticos para la formalización urbana en Piura

La evolución de los modelos predictivos en el contexto de la gestión pública y la producción agrícola

La modelización predictiva ha experimentado un desarrollo significativo en las últimas décadas, consolidándose como una herramienta indispensable para la planificación y la toma de decisiones en diversos ámbitos de la gestión pública y privada. Este avance ha sido impulsado por la creciente disponibilidad de datos históricos y el perfeccionamiento de técnicas estadísticas y computacionales que permiten extraer patrones significativos de las series temporales. En el ámbito internacional, diversos investigadores han aplicado metodologías de pronóstico a problemáticas tan diversas como la producción agrícola, la generación de energía renovable y la optimización de procesos productivos, demostrando la versatilidad y el potencial de estos enfoques para abordar desafíos concretos en contextos específicos. La literatura especializada ha documentado cómo los modelos de series temporales han evolucionado desde aproximaciones relativamente simples hasta enfoques híbridos que combinan técnicas estadísticas tradicionales con algoritmos de aprendizaje automático, ampliando significativamente el espectro de problemas que pueden abordarse mediante el pronóstico cuantitativo (Makridakis et al., 2020; Hyndman & Athanasopoulos, 2021; Petropoulos et al., 2022). Esta evolu-

ción ha sido particularmente relevante en el campo de la agricultura, donde la capacidad de anticipar rendimientos de cultivos en función de variables climáticas y otros factores determinantes se ha convertido en un elemento crucial para la seguridad alimentaria y la planificación de políticas sectoriales.

El estudio realizado por Patrick et al. (2023), constituye un referente importante en la aplicación de modelos de series temporales y de conjunto para pronosticar el rendimiento de la cosecha de banano en Tanzania, considerando los efectos del cambio climático. Estos investigadores emplearon modelos SARIMAX (Seasonal ARIMA with Exogenous Variables), Space State (SS) y Long Short-Term Memory (LSTM), seleccionados en función del análisis de regresión y la exploración de datos. Aprovechando los datos históricos de rendimiento de banano correspondientes al periodo 1961-2020 y variables climáticas relevantes, los autores compararon el rendimiento del modelo de conjunto con el de los modelos individuales para medir su efectividad. Los valores de R^2 obtenidos fueron 0.1825 para SARIMAX, 0.9835 para State Space, 0.9013 para LSTM y 0.9999 para el modelo de conjunto, lo que evidencia que el enfoque de conjunto alcanzó el valor más alto en comparación con todos los demás modelos, superándolos en los datos de validación (Patrick et al., 2023). Este hallazgo subraya la importancia de considerar estrategias de combinación de modelos cuando se

busca maximizar la precisión predictiva, particularmente en contextos donde los datos presentan comportamientos complejos que ningún modelo individual puede capturar plenamente.

En el ámbito de la energía renovable, Ruiz (2024), desarrolló un modelo de previsión eólica para estimar la producción energética de parques eólicos en el corto plazo, mediante un proceso sistemático que incluye la recolección de datos, procesamiento y limpieza, análisis estadístico, caracterización de series temporales, entrenamiento de modelos y evaluación del desempeño de las predicciones. El análisis de los resultados de pronóstico de 24 horas del modelo SARIMA arrojó un MSE de 4.738, mientras que los modelos autorregresivos (AR) y autorregresivo con predictores modificados obtuvieron valores de 3.573 y 3.292 respectivamente, demostrando que el modelo con mejor adaptabilidad a los objetivos operativos de la central eólica fue el Modelo Autoregresivo Recursivo con predictores modificados (Ruiz, 2024). Este estudio evidencia cómo la selección del modelo de pronóstico más apropiado depende no únicamente de criterios estadísticos de ajuste, sino también de la naturaleza específica del problema y de los requerimientos operativos del sistema en el que se aplica. La experiencia de Ruiz (2024), resulta particularmente ilustrativa para la presente investigación, ya que pone de manifiesto la necesidad de evaluar múltiples enfoques metodológicos antes de decidir cuál se

adapta mejor a las características particulares de los datos y a los objetivos del pronóstico.

En el contexto del sector floricultor ecuatoriano, Mejía y Páez (2023), buscaron identificar los mejores métodos para estimar el rendimiento de brotes en la finca María Bonita de Falcon Farms de Ecuador S.A., utilizando modelos clásicos de pronóstico de series temporales como Holt-Winters, SARIMAX y métodos más avanzados como el Gradient Boosting. Con datos semanales disponibles para el período 2020-2023, los resultados bajo la métrica del MAPE indicaron que Holt-Winters obtuvo 0.2632, SARIMAX logró 0.2091 y Gradient Boosting alcanzó 0.2816, lo que permitió concluir que el modelo SARIMAX fue el más preciso en comparación con los otros métodos desarrollados (Mejía & Páez, 2023). Este hallazgo resulta particularmente relevante porque demuestra que, en determinados contextos, los modelos estadísticos tradicionales pueden superar a enfoques más sofisticados de aprendizaje automático, especialmente cuando la serie temporal presenta patrones estacionales bien definidos y la longitud de los datos disponibles es limitada. La investigación de Mejía y Páez (2023), también subraya la importancia de evaluar el desempeño predictivo mediante métricas estandarizadas que permitan comparaciones objetivas entre diferentes enfoques metodológicos, una consideración que resulta central para la presente investigación en el ámbito de la titulación de propiedades.

Aplicaciones nacionales y regionales de los modelos de pronóstico en el Perú

En el contexto peruano, diversos investigadores han aplicado metodologías de series temporales a problemáticas de relevancia nacional, generando evidencia empírica que respalda la utilidad de estos enfoques en el ámbito de la gestión pública y la planificación sectorial. Carranza (2019), realizó una investigación sobre las exportaciones de bienes en la comunidad Andina durante el periodo enero 2010 a junio 2018, empleando un análisis exploratorio y la metodología de Box-Jenkins para encontrar el mejor modelo SARIMA. El estudio, de tipo descriptivo longitudinal, evidenció que la serie no presentaba estacionariedad, por lo que se aplicó una diferenciación para lograr esta condición. El modelo encontrado mediante la metodología de Box-Jenkins fue SARIMA (1,1,0) (1,1,0), cuya evaluación estuvo sujeta al porcentaje de error medio absoluto (PEMA), obteniendo un valor de 4.27%, complementado con un porcentaje medio del error (PME) de -0.04% (Carranza, 2019). Estos resultados permiten afirmar que el modelo encontrado sigue un buen desempeño en comparación con otros SARIMA alternativos, ya que ni sobreestima ni subestima las exportaciones mensuales de la comunidad andina, lo que lo convierte en una herramienta confiable para la planificación del comercio exterior.

Herrera et al. (2022) llevaron a cabo un estudio comparativo entre los modelos de pronóstico ARIMA y Holt-Winters para series temporales de producción de cereales en el Perú durante el periodo 2000-2021, con un enfoque descriptivo longitudinal y diseño no experimental. Los resultados revelaron que el modelo Holt-Winters multiplicativo ofreció el mejor ajuste para la producción de cereales, superando a ARIMA y a Holt-Winters aditivo en la mayoría de los casos analizados. Específicamente, para *Oryza sativa*, Holt-Winters multiplicativo obtuvo un BIC de 5754.20 y un AIC de 5697.48, mientras que ARIMA registró 6559.58 y 6573.75 respectivamente. Para *Zea mays* L. var. *Indurata*, el modelo multiplicativo presentó los valores más bajos con un BIC de 5060.43 y un AIC de 5003.64, frente a ARIMA que alcanzó 5490.97 y 5473.46 (Herrera et al., 2022). En el caso de *Amaranthus caudatus*, Holt-Winters multiplicativo mostró nuevamente el mejor ajuste con un BIC de 3125.35 y un AIC de 3069.85, superando a ARIMA que obtuvo 3346.38 y 3332.39. Los autores concluyeron que el modelo Holt-Winters multiplicativo demostró ser el más adecuado para capturar la estacionalidad y volatilidad de estas series de producción, hallazgo que resulta particularmente relevante para la presente investigación dado que la serie temporal de títulos de propiedad podría presentar características similares de estacionalidad y variabilidad estacional.

En el ámbito del transporte público, Roque (2022), planteó el objetivo de predecir la demanda de pasajeros en grupos de estaciones del Metropolitano de Lima mediante la aplicación de un modelo SARIMA, apoyándose en un análisis espacio-temporal con diseño no experimental de tipo descriptivo longitudinal. El análisis espacio-temporal reveló patrones de comportamiento similares entre estaciones al agruparlas en clústeres con estacionalidad semanal, aunque los modelos inicialmente no lograron predecir correctamente la demanda en días festivos anuales, ya que estas fechas fueron interpretadas como valores atípicos. Para mejorar la precisión, se ajustaron los datos de demanda de esos días festivos, logrando así una mayor exactitud en las predicciones. Los resultados finales mostraron un rendimiento robusto, con un RMSPE entre 6.37% y 8.13%, un MAPE entre 4.19% y 5.93%, y un R^2 entre 0.91 y 0.98, todos dentro de los límites de precisión establecidos como objetivos en el estudio (Roque, 2022). La investigación de Roque (2022), resulta particularmente valiosa porque evidencia cómo la combinación de técnicas de minería de datos, modelos SARIMA y la metodología Box-Jenkins resulta efectiva para capturar tendencias y estacionalidades en sistemas complejos, ofreciendo un precedente metodológico para el abordaje de series temporales con comportamiento estacional pronunciado.

En el ámbito regional, Albán (2023), desarrolló una investigación orientada a pronosticar los ingresos tributa-

rios recaudados por la SUNAT en el departamento de Piura para los trimestres de los años 2019-2021, mediante la aplicación de los modelos ARIMA y Winters con un enfoque cuantitativo y diseño no experimental de tipo predictivo-longitudinal. La muestra de estudio se compuso de datos sobre los ingresos tributarios recaudados durante los trimestres del periodo 1994-2018. Los resultados indicaron que, debido al menor error cuadrático medio, el modelo Winters con un RMSE de 27.027 resultó más eficiente que el modelo ARIMA con un RMSE de 28.119 para predecir la percepción de ingresos por la SUNAT en Piura (Albán, 2023). Esta evidencia resulta particularmente relevante para la presente investigación, ya que demuestra la aplicabilidad de los modelos de pronóstico en el contexto específico de la región Piura y sugiere que los métodos de suavizamiento exponencial como Winters pueden ser especialmente adecuados para series temporales con componentes estacionales bien definidos, como es previsible que ocurra con la entrega de títulos de propiedad en la provincia.

Arechaga y Bayona (2022), investigaron el pronóstico de la producción de arroz en cáscara en el Perú mediante modelos SARIMA para el periodo 2022-2023, utilizando el software estadístico RStudio para el procesamiento y análisis de datos. La serie de producción mensual de arroz en cáscara presentó estacionariedad y una tendencia creciente leve, demostrando además la existen-

cia de cambios cíclicos en series de más de un año. El análisis de las funciones de autocorrelación simple y parcial de la serie diferencial condujo al modelo SARIMA (0,0,2) (0,1,2), que contiene coeficientes estadísticos significativos, con un R^2 de 0.8952 y un error cuadrático medio de 56.7955 (Arechaga & Bayona, 2022). Los autores concluyeron que el modelo SARIMA proporciona una modelización adecuada de la producción de arroz en Perú y constituye el modelo a utilizar para pronosticar el período 2022-2023. Abad (2020), por su parte, buscó pronosticar el número de atenciones médicas para los años 2020 y 2021 en el servicio de hospitalización del Hospital de la Amistad Perú-Corea Santa Rosa II-2 mediante el modelo ARIMA con registros mensuales disponibles del 2009 al 2019. Durante el proceso de modelado se evaluaron tres modelos, hasta obtener finalmente el modelo ARIMA (0,1,1) con tres variables Dummy, el cual alcanzó un R^2 de 0.6415 con un coeficiente significativo al nivel del 5%, un RMSE de 79.36343 y un índice AIC de 1528.81, inferior a los valores obtenidos por los modelos ARIMA (2,0,0) y ARIMA (0,1,1) evaluados en el proceso (Abad, 2020). Las pruebas del modelo final mostraron que los residuos cumplen con los supuestos de normalidad, independencia y estacionariedad, lo que respalda su idoneidad para realizar predicciones sobre el número de pacientes atendidos en el hospital.

Fundamentos conceptuales de la propiedad, la posesión y los documentos que las acreditan

La propiedad constituye un concepto jurídico fundamental que ha sido abordado por diversos autores desde perspectivas complementarias que permiten comprender su alcance y significado en el ámbito del derecho y la sociedad. Albaladejo (1994), define la propiedad como el poder jurídico pleno sobre una cosa, enfatizando que el propietario ejerce un control absoluto sobre el objeto o bien de su titularidad. Esta definición clásica ha sido ampliada por Avendaño (2005), jurista peruano que incluye tanto bienes materiales (muebles e inmuebles) como derechos incorpóreos (como los derechos de autor y las marcas), concibiendo la propiedad como el derecho pleno que se tiene sobre un bien o cosa en sentido amplio. Por su parte, Gonzales (2012), destaca que la propiedad posee un componente económico, útil y social, confiriendo al titular poderes materiales como el uso y goce, y poderes jurídicos como la disposición y la reivindicación. Esta visión multidimensional de la propiedad resulta particularmente relevante para comprender la importancia de la titulación formal en contextos urbanos, donde la seguridad jurídica que proporciona el título de propiedad habilita a las familias para acceder a servicios crediticios, mejorar sus viviendas y participar plenamente en la vida económica y social de sus comunidades (Federico, 2020; Torero, 2021).

El título de propiedad es un documento legal que identifica a una persona física o jurídica como propietaria de un bien, ya sea mueble o inmueble, otorgándole derechos plenos sobre ese bien. Jiménez y González (2019), precisan que este documento puede contener información detallada sobre la propiedad, incluyendo su descripción, ubicación y términos de transferencia de propiedad. En el contexto de los asentamientos humanos y las urbanizaciones populares de interés social, los requisitos para la obtención del título de propiedad incluyen la solicitud del interesado dirigida a la unidad orgánica competente, el certificado negativo de propiedad emitido por registros públicos, copia del Documento Nacional de Identidad de los titulares, copia de la partida de matrimonio civil o declaración jurada de convivencia cuando corresponda, declaración jurada de separación de hecho en caso de estar separados, documento de traspaso legalizado ante notario público cuando sea necesario, pagos por adjudicación y por título de propiedad, así como copia de recibo de luz de servicio activo y copia del autovaluó. Para el caso de caseríos y centros poblados, los requisitos son similares, pero con algunas variaciones que responden a la naturaleza y características de estas zonas de menor densidad poblacional, lo que evidencia la necesidad de adecuar los procedimientos administrativos a las realidades territoriales específicas.

La posesión, como concepto jurídico diferenciado de la propiedad, ha sido analizada por Cuadros (2019), quien retoma la definición de Ramírez al señalar que la posesión inicialmente constituye un hecho, pero rápidamente se convierte en un derecho vinculado a la seguridad de la propiedad, independientemente de que esta sea temporal o transitoria, a diferencia de la propiedad que conlleva derechos plenos. Los derechos de propiedad se rigen por el principio de legalidad, lo que establece un marco normativo que diferencia claramente entre el simple poseedor y el propietario legal. La posesión se caracteriza por varios elementos distintivos: la ley presume que quien posee algo es el legítimo titular de ese derecho; la posesión crea una impresión de titularidad sobre la propiedad; está amparada por el Código Civil y puede ser ejecutada por cualquier persona física o jurídica; y puede recaer sobre cosas y derechos que son fácilmente enajenables. En cuanto a las clases de posesión, se distingue entre posesión mediata (vinculada a contratos de arrendamiento, donde el arrendatario es poseedor directo), posesión inmediata (posesión de hecho según el propio contrato de arrendamiento), posesión ostentada por el verdadero titular (donde propietario y poseedor coinciden sobre el terreno) y posesión ostentada por una persona que no es el titular (cuando alguien es propietario de una vivienda, pero permite que otro la utilice). En síntesis, la posesión constituye el control físico sobre un bien, mientras que

la propiedad representa el derecho legal completo sobre ese bien, pudiendo existir casos en los que la posesión no implica propiedad y viceversa.

Los documentos que acreditan la propiedad constituyen elementos fundamentales en el proceso de formalización y titulación. El profesional responsable de calificación debe verificar la existencia de propiedad sobre el lote cuando se presenten títulos de propiedad otorgados por la municipalidad provincial o distrital, siempre que la facultad de titulación de dichos municipios se ampare en una ley vigente a la fecha de su emisión; o tratándose de municipalidades distritales, que se amparen en una ordenanza de la municipalidad provincial vigente a la fecha de su emisión. También están comprendidos los títulos de propiedad emitidos con carácter provisional para ser canjeados por títulos definitivos por las municipalidades provinciales, así como los documentos de transferencia otorgados a título gratuito u oneroso por entidades del Estado competentes que en su oportunidad tuvieron la facultad de transferir la propiedad en virtud de leyes vigentes en ese entonces. En estos casos, se procederá a la emisión del título de saneamiento a favor del titular del derecho, aun cuando este no se encuentre en posesión del lote, siempre que se haya determinado que el documento de propiedad corresponde al predio materia de formalización (Abad, 2020). Entre los documentos que acreditan la posesión se incluyen el título expedido por la municipalidad provin-

cial o distrital, contratos de préstamo para instalación de servicios básicos, recibos de servicios básicos emitidos al nombre del poseedor, declaraciones juradas o recibos de pago del valor real del inmueble, permisos de residencia o certificados de posesión, y documentos públicos o privados que acrediten la transferencia de la posesión plena (Albán, 2023). En caso de que los poseedores no cuenten con documentación suficiente, se deberá tomar la declaración escrita de al menos cuatro vecinos colindantes, estableciendo así un mecanismo de validación social que complementa la evidencia documental cuando esta resulta insuficiente.

Las series temporales y los modelos de pronóstico como herramientas para la planificación

Una serie temporal se expresa como un proceso estocástico que establece una familia de variables aleatorias que cambian con el tiempo, constituyendo una secuencia organizada de datos recopilados y ordenados temporalmente sobre un sistema específico. Carroll (2019) ha señalado que el tiempo es la dimensión en la que ocurren los acontecimientos, permitiendo determinar su orden y duración, conceptualizándose como una cantidad que interactúa con el espacio para crear lo que se denomina espacio-tiempo, en el que el tiempo puede relacionarse con

la velocidad y la gravedad. Las observaciones en una serie temporal se registran de manera discreta durante un período de tiempo regular o irregular, y el análisis de estos datos se basa principalmente en el cálculo de parámetros que permiten obtener información sobre las características de los datos y del sistema que los generó (Christou & Fokianos, 2015). El objetivo fundamental del análisis de series temporales es explicar las variaciones observadas en la secuencia pasada, identificando patrones específicos, para luego pronosticar el comportamiento futuro de la variable en estudio (Florenxia, 2018). Esta aproximación metodológica resulta particularmente relevante para la gestión pública, donde la capacidad de anticipar tendencias y comportamientos futuros permite diseñar intervenciones más efectivas y asignar recursos de manera más eficiente (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020).

Las series temporales se caracterizan por sus componentes fundamentales: la tendencia, que constituye el componente de largo plazo que establece la base del crecimiento o decrecimiento de la serie, definiéndose por el movimiento suave de la serie a largo plazo; la estacionalidad, que se refiere a los patrones que se repiten de un período a otro, afectando la serie por factores estacionales de duración fija como el día, mes o trimestre; los ciclos, que representan cambios en la tendencia subyacente causados por diversos factores que difieren de la estacionalidad y

no siempre tienen una duración y tiempo constantes; y la aleatoriedad, constituida por las fluctuaciones impredecibles o no cíclicas que subyacen a la serie (Gambini & López, 2018). Para el análisis de series temporales, se utilizan dos modelos principales: el modelo aditivo, que supone que el valor de los datos originales es la suma de las cuatro componentes ($Y_t = T_t + E_t + C_t + I_t$), y el modelo multiplicativo, que supone que el valor de los datos originales es el producto de las cuatro componentes ($Y_t = T_t \times E_t \times C_t \times I_t$). La elección entre estos modelos depende de las características específicas de la serie y de si los componentes estacionales varían proporcionalmente al nivel de la serie o se mantienen constantes en magnitud (Hyndman & Athanasopoulos, 2021).

Los métodos de proyección basados en series temporales analizan cuidadosamente los patrones de datos a lo largo del tiempo y extrapolan estos patrones hacia el futuro basándose únicamente en los valores pasados de la variable objetivo (Villarreal, 2016). Entre las técnicas más utilizadas se encuentran los métodos de suavizamiento exponencial, que calculan un promedio ponderado de valores de series temporales pasadas para predecir valores futuros, permitiendo obtener rápidamente pronósticos confiables para una amplia gama de series temporales (Pathak, 2021). El método de Holt-Winters, en particular, puede utilizarse de forma aditiva o multiplicativa, prefiriéndose el método aditivo para series con tendencias

lineales y patrones estacionales independientes del nivel de la serie, mientras que el modelo multiplicativo resulta más adecuado para series con tendencias lineales y patrones estacionales que varían con el nivel (Flores, 2018).

El modelo Holt-Winters multiplicativo: es una extensión avanzada del suavizamiento exponencial, presupone que a medida que se incrementan los datos, también se incrementa el patrón estacional, situación que se observa comúnmente en gráficas de series temporales (Villaverde, 2017). En este modelo, la tendencia y los componentes estacionales se multiplican y luego se suman al componente de error, siendo particularmente útil para datos que presentan tanto tendencias como estacionalidades, ya que considera que los efectos estacionales varían proporcionalmente al nivel de la serie temporal. Las ecuaciones del modelo Holt-Winters multiplicativo incluyen tres ecuaciones de suavizamiento: una para el nivel, una para la tendencia y otra para la estacionalidad, junto con la ecuación de pronóstico que combina estos tres componentes. La estimación de los parámetros de suavizamiento se realiza típicamente mediante la minimización del error cuadrático medio o mediante criterios de información como AIC o BIC, permitiendo así calibrar el modelo de manera óptima para la serie temporal en estudio (Hyndman & Athanasopoulos, 2021; Gardner, 2019).

$$\ell_t = \alpha \left(\frac{y_t}{S_{t-4}} \right) + (1 - \alpha)(\ell_{t-1} + b_{t-1}), (1)$$

$$b_t = \gamma(\ell_t - \ell_{t-1}) + (1 - \gamma)b_{t-1}, (2)$$

$$S_t = \delta \left(\frac{y_t}{\ell_{t-1} - b_{t-1}} \right) + (1 - \delta)S_{t-4}, (3)$$

$$\hat{y}_{t+k|t} = (\ell_t + kb_1)S_{t+h-4(h+1)}, (4)$$

donde α , γ y δ son parámetros de suavizado del nivel, de la pendiente y de la estacionalidad respectivamente, que satisfacen $0 \leq \alpha, \gamma, \delta \leq 1$. Se calculan estos tres parámetros al minimizar el error cuadrático medio entre y_{t+1} e $\hat{y}_{t+1|t}$.

En las primeras 3 igualdades, llamadas ecuaciones de estado, el nivel ℓ_t de la Ecuación (1) es la media ponderada entre la observación ajustada por la estacionalidad interanual $\left(\frac{y_t}{S_{t-4}} \right)$ y el pronóstico no estacional para el tiempo $t - 1$, $(\ell_{t-1} + b_{t-1})$. La tendencia b_t de la Ecuación (2) es la media ponderada entre el cambio de nivel, $(\ell_t - \ell_{t-1})$, y la estimación anterior de la tendencia, b_{t-1} . Por último, la estacionalidad S_t de la Ecuación (3) es la media ponderada entre el índice de estacionalidad actual, $\left(\frac{y_t}{\ell_{t-1} - b_{t-1}} \right)$ y el índice de estacionalidad del trimestre t del año anterior, S_{t-4} .

La Ecuación (4), de observación, describe el pronóstico de y_t mediante Holt-Winters multiplicativo dentro de la muestra un paso hacia adelante. Sea T el número de

observaciones de la serie. Para k períodos hacia adelante fuera de la muestra ($k \in \mathbb{N}$), el pronóstico se da por:

$$\hat{y}_{T+k|T} = (\ell_T + kb_T)S_{T+h-4(h+1)}, (5)$$

donde h es la parte entera de $\frac{(k-1)}{4}$ lo que asegura que las estimaciones de los índices de estacionalidad empleados para hacer los pronósticos provienen del último año de la muestra.

Método de Holt-Winters aditivo: es una técnica de suavizamiento exponencial ampliamente reconocida por su efectividad en el pronóstico de series temporales que presentan simultáneamente componentes de tendencia y estacionalidad. Según Villaverde (2017), este modelo se fundamenta en la premisa de que los efectos de los factores individuales pueden diferenciarse y agruparse sistemáticamente para modelar adecuadamente los datos observados. El modelo aditivo, que puede utilizarse tanto en procedimientos de descomposición como en el método de Winters propiamente dicho, destaca por su capacidad para descomponer una serie temporal en tres componentes esenciales: nivel, tendencia y estacionalidad, y luego proyectarlos hacia el futuro para generar pronósticos precisos. A diferencia del enfoque multiplicativo, que ajusta la estacionalidad de manera proporcional al nivel de la serie temporal, el modelo aditivo supone que los componentes estacionales son constantes y se suman directamente al nivel de la serie. Esta característica implica que la variación estacional permanece constante en magnitud,

independientemente del nivel de la serie temporal, lo que hace que el modelo aditivo sea particularmente adecuado cuando los datos muestran un patrón estacional consistente que no varía con el nivel de los datos. Este enfoque resulta especialmente valioso para series temporales con variación estacional constante a lo largo del tiempo, como ocurre frecuentemente en indicadores de gestión pública que responden a ciclos administrativos regulares (Hyndman & Athanasopoulos, 2021; Gardner, 2019; Taylor, 2020).

El modelo Holt-Winters aditivo resulta de las siguientes igualdades:

$$\ell_t = \alpha(y_t - S_{t-4}) + (1 - \alpha)(\ell_{t-1} + b_{t-1}), (6)$$

$$b_t = \gamma(\ell_t - \ell_{t-1}) + (1 - \gamma)b_{t-1}, (7)$$

$$S_t = \delta(y_t - \ell_{t-1} - b_{t-1}) + (1 - \delta)S_{t-4}, (8)$$

$$\hat{y}_{T+k|T} = \ell_T + kb_T + S_{t+k-4(h+1)}, (9)$$

donde α , γ y δ son parámetros de suavizado del nivel, de la pendiente y de la estacionalidad respectivamente, que satisfacen $0 \leq \alpha, \gamma, \delta \leq 1$. Se calculan estos tres parámetros al minimizar el error cuadrático medio entre y_{t+1} e $\hat{y}_{t+1|t}$.

En las ecuaciones de estado, el nivel ℓ_t de la Ecuación (6) es la media ponderada entre la observación ajustada por la estacionalidad interanual ($y_t - S_{t-4}$) y el pronóstico

no estacional para el tiempo $t-1$, $(\ell_{t-1} + b_{t-1})$. La tendencia b_t de la Ecuación (7) se calcula de la misma manera que en el método multiplicativo de la Ecuación (2). Además, de la Ecuación (8) se tiene que la estacionalidad S_t es la media ponderada entre el término estacional actual, $(y_t - \ell_{t-1} - b_{t-1})$, y el término estacional del trimestre t del año anterior, S_{t-4} . Finalmente, en relación a la Ecuación (5) de observación, la Ecuación (9) describe el pronóstico de y_t mediante Holt-Winters aditivo para k períodos hacia adelante fuera de la muestra.

La utilidad del modelo aditivo de Holt-Winters trasciende el ámbito estrictamente metodológico para extenderse a diversos campos aplicados donde los patrones estacionales tienden a mantenerse estables en el tiempo. En el ámbito económico, este modelo ha demostrado ser particularmente efectivo para el pronóstico de indicadores macroeconómicos como el producto interno bruto, la inflación o el desempleo, que suelen presentar fluctuaciones estacionales asociadas a ciclos productivos o de consumo que se repiten año tras año con una magnitud relativamente constante (Makridakis et al., 2020; Petropoulos et al., 2022). En el sector empresarial, el modelo aditivo de Holt-Winters ha sido ampliamente utilizado para el pronóstico de ventas y la planificación de inventarios, permitiendo a las organizaciones anticipar la demanda estacional de productos y servicios y optimizar así sus operaciones logísticas y comerciales (Fildes & Good-

win, 2021; Armstrong, 2020). Asimismo, en el campo de la meteorología, este enfoque ha contribuido a mejorar la precisión de los pronósticos climáticos estacionales, facilitando la planificación agrícola y la gestión de recursos hídricos (Blasetti, 2022; Chatfield, 2019). La evidencia empírica disponible sugiere que el modelo aditivo de Holt-Winters ofrece una herramienta poderosa y flexible para hacer pronósticos cuando los patrones estacionales son constantes en magnitud, permitiendo a analistas y planificadores hacer predicciones más precisas y fundamentadas (Blasetti, 2022; Herrera et al., 2022). Esta característica convierte al modelo aditivo en una opción metodológica particularmente apropiada para contextos donde la estabilidad de los patrones estacionales puede ser asumida con confianza, como ocurre en el caso de la entrega de títulos de propiedad en una provincia con procedimientos administrativos y ciclos presupuestales relativamente estables a lo largo del tiempo.

Metodología de Box-Jenkins: formalizada en 1976, constituye un enfoque sistemático y riguroso para el análisis y pronóstico de series temporales, fundamentándose en la premisa de que las series a predecir son generadas por procesos estocásticos cuya naturaleza puede ser caracterizada mediante un modelo específico que capture su estructura de dependencia temporal (Box et al., 2008). Estas técnicas, ampliamente utilizadas en el análisis de series temporales, permiten predecir valores futuros de

una variable basándose exclusivamente en sus valores pasados, estableciendo una relación funcional entre la historia de la serie y su evolución futura que se expresa en términos de una combinación lineal de observaciones previas (Wei, 2018). Para que estos modelos sean efectivos, es necesario que la serie temporal cumpla con ciertas condiciones fundamentales, como la estacionariedad en media y varianza, y la presencia de autocorrelación significativa entre las observaciones, aspectos que deben ser verificados mediante pruebas estadísticas apropiadas antes de proceder con la estimación del modelo (Shumway & Stoffer, 2017). La utilidad de los modelos Box-Jenkins se extiende a diversos contextos donde las series temporales presentan patrones consistentes y estables, como ocurre con los precios financieros, los datos meteorológicos o los índices económicos, permitiendo que el modelo capture y aproveche los patrones históricos para generar predicciones útiles y de precisión razonable (Chatfield, 2003). La metodología se distingue por su enfoque iterativo, que comprende tres etapas fundamentales: identificación, estimación y verificación, cada una de las cuales contribuye a garantizar la validez y robustez del modelo final (Hyndman & Athanasopoulos, 2018). Sin embargo, la precisión de estos modelos se ve limitada en series temporales no estacionarias o altamente volátiles, donde podrían ser necesarias transformaciones adicionales como la diferenciación regular o estacional para lograr un comportamiento estacionario antes de aplicar el modelo autorregresivo

(Brockwell & Davis, 2016). Cuando la autocorrelación es insuficiente para capturar adecuadamente la estructura de dependencia temporal, modelos más complejos como ARIMA o SARIMA pueden ser más efectivos, ya que incorporan diferencias estacionales y adicionales que permiten modelar una gama más amplia de comportamientos temporales, ofreciendo así una herramienta metodológica flexible y poderosa para el pronóstico en diversos campos aplicados (Ljung & Box, 2018; McLeod et al., 2019).

Método de Media Móvil (MA): constituye una técnica fundamental en el análisis de series temporales, caracterizada porque los pronósticos se basan en errores de predicción pasados en lugar de valores anteriores de la serie, lo que la distingue claramente de los modelos autorregresivos. A diferencia de estos últimos, el modelo MA utiliza los errores de pronóstico de observaciones previas para proyectar valores futuros, lo que implica que cada valor de la serie se representa como una combinación de los errores aleatorios de períodos anteriores, generando un modelo que, aunque similar a una regresión, depende de los residuos en lugar de los valores mismos de la variable (Pathak, 2021). Esta característica confiere al modelo MA una utilidad particular para captar patrones a corto plazo en series temporales ruidosas, es decir, aquellas con variabilidad aleatoria significativa, al reducir el impacto de fluctuaciones no sistemáticas y hacer el pronóstico más robusto en términos de ruido y errores (Ríos & Hurtado,

2008). La efectividad del modelo MA radica en su capacidad para filtrar el ruido aleatorio y extraer la señal subyacente, permitiendo generar predicciones que reflejan la dinámica esencial de la serie sin ser distorsionadas por perturbaciones transitorias, lo que resulta especialmente valioso en contextos donde los datos presentan alta volatilidad o mediciones imprecisas (Chatfield, 2019; Hyndman & Athanasopoulos, 2021). Según Romero (2021), un proceso de media móvil de primer orden, MA(1), se define detalladamente como aquel en el que el valor actual de la serie depende únicamente del error aleatorio actual y del error del período inmediatamente anterior, ponderados por un coeficiente que determina la intensidad de la influencia del error rezagado sobre el valor presente. La correcta especificación del orden del modelo MA requiere el análisis de la función de autocorrelación parcial y la aplicación de criterios de información como AIC o BIC, que permiten seleccionar el número de rezagos de error que mejor capturan la estructura de dependencia temporal presente en los datos (Brockwell & Davis, 2016; Wei, 2018).

Sea $\{\epsilon_t\}_{t=-\infty}^{\infty}$ un proceso ruido blanco.

Se define el proceso MA(1) como:

$$y_t = \mu + \epsilon_t + \theta \epsilon_{t-1}$$

$$y_t = \mu + (1 + \theta L)\epsilon_t$$

Su valor esperado es:

$$y_t = \mu + \mathbb{E}[\epsilon_t] + \theta \mathbb{E}[\epsilon_{t-1}]$$

$$y_t = \mu + 0 + \theta 0$$

$$y_t = \mu$$

Su varianza es

$$\text{Var}[y_t] \equiv \mathbb{E}(y_t - \mathbb{E}[y_t])^2$$

$$\text{Var}[y_t] = \mathbb{E}[(y_t - \mu)^2]$$

$$\text{Var}[y_t] = \mathbb{E}[(\epsilon_t + \theta \epsilon_{t-1})^2]$$

$$\text{Var}[y_t] = \mathbb{E}[\epsilon_t^2 + 2\theta \epsilon_t \epsilon_{t-1} + \theta^2 \epsilon_{t-1}^2]$$

$$\text{Var}[y_t] = \mathbb{E}[\epsilon_t^2] + 2\theta \mathbb{E}[\epsilon_t \epsilon_{t-1}] + \theta^2 \mathbb{E}[\epsilon_{t-1}^2]$$

$$\text{Var}[y_t] = \sigma^2 + 2\theta \times 0 + \theta^2 \sigma^2$$

$$\text{Var}[y_t] = (1 + \theta^2) \sigma^2$$

Su covarianza se expresa:

$$\text{Cov}[y_t, y_{t-j}] = \mathbb{E}[(y_t - \mu)(y_{t-j} - \mu)]$$

$$= \mathbb{E}[(\epsilon_t + \theta \epsilon_{t-1})(\epsilon_{t-j} + \theta \epsilon_{t-j-1})]$$

$$= \mathbb{E}[\epsilon_t \epsilon_{t-j} + \theta \epsilon_t \epsilon_{t-j-1} + \theta \epsilon_{t-1} \epsilon_{t-j} + \theta^2 \epsilon_{t-1} \epsilon_{t-j-1}]$$

$$= 0 + \theta \times 0 + \theta \mathbb{E}[\epsilon_{t-1} \epsilon_{t-j}] + \theta^2 \times 0$$

$$= \theta \mathbb{E}[\epsilon_{t-1} \epsilon_{t-j}] = \begin{cases} \theta \sigma^2, & \text{si } j = 1 \\ 0, & \text{si } j > 1 \end{cases}$$

Por lo tanto, su función de autocorrelación es:

$$\rho_j = \begin{cases} \frac{\theta}{1 + \theta^2}, & \text{si } j = 1 \\ 0, & \text{si } j > 1 \end{cases}$$

Método de Regresión Autorregresivo (AR):

es un modelo fundamental en el análisis de series temporales, caracterizado porque representa el valor actual de una variable como función de una combinación lineal de sus valores pasados, aplicando un conjunto de coeficientes que ponderan la importancia relativa de cada observación anterior en la determinación del valor presente (Ríos & Hurtado, 2008). En este enfoque, cada valor futuro es una suma ponderada de los valores históricos, lo que permite capturar patrones de autocorrelación y dependencia temporal dentro de la serie, reflejando la inercia o persistencia característica de muchos procesos económicos, financieros y sociales. Este modelo resulta particularmente efectivo cuando la serie exhibe autocorrelación significativa, es decir, cuando los valores de la serie dependen de manera sustancial de sus valores anteriores, como ocurre frecuentemente con indicadores macroeconómicos, precios de activos financieros o variables climáticas que presentan una estructura de memoria temporal (Hyndman & Athanasopoulos, 2021; Brockwell & Davis, 2016). La especificación del orden del modelo AR, que determina el número de rezagos incluidos, se realiza típicamente mediante el análisis de la función de autocorrelación parcial y la aplicación de criterios de información como AIC o BIC, que permiten seleccionar el modelo que mejor equilibra la bondad de ajuste con la parsimonia (Wei, 2018). Al modelar cada punto en el tiempo como

una suma ponderada de sus valores precedentes, el modelo AR puede capturar con precisión los patrones internos y tendencias en la serie, lo cual es esencial en contextos de análisis y pronóstico de datos temporales donde la comprensión de la dinámica subyacente resulta crucial para la toma de decisiones fundamentadas (Chatfield, 2019). La literatura especializada ha documentado que los modelos autorregresivos, cuando se especifican adecuadamente, ofrecen predicciones precisas y estables, particularmente en series temporales que presentan una estructura de dependencia lineal y donde los supuestos de estacionariedad se cumplen satisfactoriamente (Shumway & Stoffer, 2017; Petropoulos et al., 2022).

Según Romero (2021), para un proceso autorregresivo de primer orden AR(1):

Sea $\{\epsilon_t\}_{t=-\infty}^{\infty}$ un proceso ruido blanco.

Se define el proceso AR(1) como:

$$y_t = c + \phi y_{t-1} + \epsilon_t$$

$$y_t - \phi y_{t-1} = c + \epsilon_t$$

$$(1 - \phi L)y_t = c + \epsilon_t$$

Siempre que $|\phi| < 1$ podemos invertir el término $(1 - \phi L)$

$$\begin{aligned}
 y_t &= (1 - \phi L)^{-1}(c + \epsilon_t) \\
 &= (1 - \phi L)^{-1}c + (1 - \phi L)^{-1}\epsilon_t \\
 &= \frac{c}{1 - \phi} + (1 + \phi L + \phi^2 L^2 + \dots)\epsilon_t \\
 &= \frac{c}{1 - \phi} + \epsilon_t + \phi\epsilon_{t-1} + \phi^2\epsilon_{t-2} + \dots
 \end{aligned}$$

Vemos por tanto que si $|\phi| < 1$, el proceso AR(1) puede escribirse como el proceso $MA(\infty)$

$$y_t = \frac{c}{1 - \phi} + \epsilon_t + \phi\epsilon_{t-1} + \phi^2\epsilon_{t-2} + \dots$$

Por lo que su valor esperado es:

$$\mathbb{E}[y_t] \equiv \mu = \frac{c}{1 - \phi}$$

y su varianza es:

$$Var[y_t] \equiv \gamma_0 = (1 + \phi^2 + \phi^4 + \phi^6 + \dots)\sigma^2$$

$$Var[y_t] = \frac{\sigma^2}{1 - \phi^2}$$

La representación $MA(\infty)$ nos muestra que y_t depende de la perturbación presente ϵ_t y de todas las pasadas ϵ_{t-1} , ϵ_{t-2} , ..., pero no depende de ninguna de las perturbaciones futuras ϵ_{t+1} , ϵ_{t+2} , ...

Por ello, la covarianza de y_t con cualquier perturbación posterior ϵ_{t+k} (con $k > 0$) es cero.

Modelo Autorregresivo de Media Móvil (ARMA): es una herramienta fundamental en el análisis de series temporales al integrar los componentes autorregresivos (AR) y de media móvil (MA), permitiendo que los valores futuros se predigan mediante una combinación de observaciones pasadas y errores anteriores (Ríos & Hurtado, 2008). Esta integración facilita la captura de patrones complejos basados tanto en los valores actuales como en los rezagados de la serie, ofreciendo una representación más completa de la estructura de dependencia temporal subyacente. Los procesos ARMA resultan especialmente relevantes porque permiten aproximar de manera efectiva cualquier proceso estacionario, lo que los convierte en una opción metodológica versátil para el análisis de series temporales en diversos campos aplicados. Romero (2021) señala que esta capacidad de aproximación hace que el modelo ARMA sea fundamental, ya que un amplio rango de series temporales estacionarias puede representarse adecuadamente a través de este tipo de modelo, proporcionando una estructura más comprensiva para el análisis y pronóstico en contextos donde la estacionariedad es un supuesto verificable.

Similar a lo que encontramos con los procesos $AR(p)$, si asumimos que es estacionario, su media satisface la relación:

$$mu = c + \phi_1\mu + \dots + \phi_p$$

Por lo que el proceso puede escribirse sin el intercepto, si expresamos la variable y como desviación de su media:

$$\tilde{y}_t = \phi_1\tilde{y}_{t-1} + \dots + \phi_p\tilde{y}_{t-p} + \epsilon_t + \theta_1\epsilon_{t-1} + \dots + \theta_q\epsilon_{t-q}$$

Modelo Autorregresivo Integrado de Media Móvil (ARIMA): constituye una técnica estadística avanzada ampliamente utilizada en el análisis de series temporales, particularmente para pronósticos cuando los datos presentan tendencias o patrones no estacionarios que requieren transformaciones previas para su modelización adecuada. El término ARIMA corresponde a tres componentes fundamentales que aportan aspectos específicos al modelo: AR (Autorregresión), que utiliza valores anteriores de la serie para estimar valores futuros; MA (Media Móvil), que incorpora los errores de predicciones previas; e I (Integración), que aplica una diferenciación a la serie para convertir datos no estacionarios en estacionarios, condición esencial para el análisis (Florencia, 2018). Este método permite expresar el valor actual de una serie como una combinación lineal de sus valores pasados junto con errores aleatorios, ofreciendo una representación flexible de la dinámica temporal subyacente. Los modelos ARIMA resultan especialmente útiles en contextos donde la serie temporal presenta una tendencia

clara y no es estacionaria, ya que, al aplicar el modelo, la serie se transforma mediante diferencias que eliminan las tendencias y producen datos estacionarios, facilitando así el pronóstico preciso en una amplia variedad de campos (Guerrero & Medina, 2016). A diferencia de otros modelos que dependen de variables independientes, un ARIMA es puramente dinámico, ya que sus estimaciones futuras se basan únicamente en el historial de la propia serie, lo que permite capturar la estructura y variaciones inherentes en los datos sin necesidad de incorporar factores externos, característica que lo convierte en una herramienta especialmente valiosa para el análisis de indicadores de gestión pública con patrones temporales bien definidos (Hyndman & Athanasopoulos, 2021; Chatfield, 2019).

El modelo ARIMA (p, d, q) se puede representar como:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

en donde d corresponde a las d diferencias que son necesarias para convertir la serie original en estacionaria, $\phi_1, \dots, \phi_p$ son los parámetros pertenecientes a la parte “autorregresiva” del modelo, $\phi_1, \dots, \phi_p$ los parámetros pertenecientes a la parte “medias móviles” del modelo, ϕ_0 es una constante, y ε_t es el término de error (llamados también innovaciones). Se debe tomar en cuenta que:

$$\Delta Y_t = Y_t - Y_{t-1}$$

Modelo Autorregresivo Integrado de Media Móvil Estacional (SARIMA): El modelo Autorregresivo Integrado de Media Móvil Estacional (SARIMA) constituye una herramienta metodológica ampliamente utilizada para analizar y predecir datos que presentan patrones estacionales, constituyendo una extensión del conocido modelo ARIMA al cual se le añaden componentes estacionales para manejar adecuadamente las series temporales con fluctuaciones periódicas. Según Pathak (2021), SARIMA es similar a ARIMA pero incluye un componente adicional de estacionalidad que permite manejar datos con patrones estacionales, cuyos parámetros correspondientes capturan las fluctuaciones estacionales presentes en los datos, lo que lo convierte en una opción particularmente valiosa para contextos donde las variaciones periódicas son un rasgo distintivo del comportamiento de la serie. El modelo SARIMA incorpora factores estacionales y no estacionales en un modelo multiplicativo, cuya notación abreviada se expresa como:

$$ARIMA(p, d, q) \times (P, D, Q)_s$$

El componente autorregresivo (AR) muestra la relación entre una observación y un número de observaciones anteriores, capturando la persistencia o inercia característica de muchos procesos temporales. El componente inte-

grado (I) indica el número de veces que las observaciones deben diferenciarse para hacer que la serie temporal sea estacionaria, condición fundamental para la aplicabilidad del modelo. El componente de media móvil (MA) expresa la relación entre una observación y un número de errores de pronóstico anteriores, permitiendo modelar el impacto de perturbaciones aleatorias pasadas sobre el valor presente. Finalmente, el componente estacional (S) agrega elementos para capturar la estacionalidad en los datos, tales como patrones repetitivos anuales, mensuales o de cualquier otra periodicidad relevante para el fenómeno en estudio (Hyndman & Athanasopoulos, 2021; Wei, 2018). Donde:

- p = orden *AR* no estacional,
- d = orden de diferencias no estacional,
- q = orden *MA* no estacional,
- P = orden *AR* estacional,
- D = orden de diferencia estacional,
- Q = orden *MA* estacional y
- S = ventana de temporal del patrón estacional

Sin cálculo diferencial, el modelo se puede escribir más formalmente como:

$$\Phi(Bs)\phi(B)(xt - \mu) = \theta(Bs)\theta(B)wt$$

Componentes no estacionales:

$$\text{AR: } \phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

$$\text{MA: } \theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$$

Componentes estacionales:

$$\text{AR: } \Phi(B) = 1 - \Phi_1 B^S - \dots - \Phi_P B^{PS}$$

$$\text{MA: } \Theta(B) = 1 + \Theta_1 B^S + \dots + \Theta_Q B^{QS}$$

Evaluación de modelos predictivos y marco institucional para el pronóstico de títulos de propiedad

Criterios y métricas para la evaluación del desempeño predictivo en series temporales

La evaluación del desempeño de los modelos de pronóstico constituye una etapa fundamental en el análisis de series temporales, ya que permite determinar la capacidad predictiva de las diferentes metodologías y seleccionar aquella que ofrece estimaciones más precisas y confiables. La literatura especializada ha establecido que la evaluación depende principalmente de la diferencia entre el valor predicho y el valor real observado, estableciendo que cuanto menor sea esta discrepancia, mejor será el efecto

de pronóstico del modelo (Zhao et al., 2023). La elección de la métrica de desempeño adecuada depende del problema específico y del objetivo del análisis, por lo que resulta esencial comprender las propiedades y limitaciones de cada indicador disponible (Hyndman & Koehler, 2006; Makridakis et al., 2020). Las métricas de evaluación comunes para el pronóstico de series temporales incluyen el error cuadrático medio (MSE), el error medio absoluto (MAE) y el error porcentual absoluto medio (MAPE), cada uno de los cuales ofrece una perspectiva diferente sobre la precisión del modelo y presenta ventajas y desventajas según el contexto de aplicación (Subramanian et al., 2023; Chugh, 2020). El MSE se halla mediante la diferencia media cuadrática entre los valores previstos y reales, y elimina grandes errores debido a su comportamiento cuadrático, lo que lo hace particularmente sensible a valores atípicos que pueden distorsionar significativamente la evaluación del modelo. El MAE se calcula como la media de las diferencias absolutas entre los valores reales y predichos, representando la media de los datos residuales en la misma escala de la variable original, lo que facilita su interpretación práctica. El MAPE, por su parte, expresa la diferencia absoluta media entre los valores ajustados por el modelo y los valores observados como porcentaje, ofreciendo una medida independiente de la escala que permite comparar el desempeño predictivo entre diferentes series temporales o contextos de aplicación (Sánchez,

2020). Adicionalmente, el R^2 Score constituye una medida estadística que expresa la proporción de variación en la variable dependiente que puede predecirse a partir de las variables independientes, utilizándose frecuentemente para evaluar el ajuste de modelos de regresión y proporcionando una indicación de la bondad de ajuste global del modelo.

La correcta interpretación de estas métricas requiere considerar que cada una privilegia aspectos distintos del error de pronóstico, por lo que la selección del indicador más apropiado debe basarse en las características específicas del problema y en los objetivos de la investigación. El MSE, al elevar al cuadrado las diferencias, penaliza desproporcionadamente los errores grandes, lo que puede ser deseable cuando se quiere evitar pronósticos con desviaciones extremas, pero puede resultar problemático cuando los valores atípicos no son representativos del comportamiento típico de la serie (Willmott & Matsuura, 2019; Chai & Draxler, 2014). El MAE, al tratar todos los errores de manera lineal, ofrece una medida más robusta frente a valores atípicos y resulta más fácil de interpretar en términos prácticos, ya que expresa el error promedio en las mismas unidades que la variable pronosticada. El MAPE, por su parte, proporciona una medida relativa del error que facilita la comparación entre diferentes modelos o series, pero puede presentar problemas cuando los valores reales son cercanos a cero, ya que el denomina-

dor de la fracción tiende a infinito y distorsiona la métrica (Hyndman, 2020; Petropoulos et al., 2022). En el contexto de la presente investigación, donde se busca comparar la precisión de los modelos Holt-Winters y Box-Jenkins para el pronóstico de títulos de propiedad, el MAPE resulta particularmente adecuado por su independencia de la escala y su amplia aceptación en la literatura especializada, aunque se recomienda complementar su uso con el MAE para obtener una evaluación más completa del desempeño predictivo (Armstrong, 2020; Fildes & Goodwin, 2021).

Marco institucional y legal para la formalización de la propiedad en la provincia de Piura

La formalización de la propiedad en la provincia de Piura se enmarca en un conjunto de disposiciones legales e institucionales que establecen los procedimientos, requisitos y competencias para la titulación de terrenos ocupados por posesiones informales, centros urbanos informales y urbanizaciones populares. La Municipalidad Provincial de Piura, como entidad responsable de la gestión del territorio y la provisión de servicios públicos, tiene como política institucional construir una región segura, inclusiva, moderna y competitiva, que brinde servicios públicos de alta calidad, mejore la calidad de vida de sus habitantes y promueva el desarrollo económico y

la actividad económica local. Para lograr estos objetivos, la institución desarrolla acciones que priorizan la lucha contra la corrupción, la seguridad ciudadana, la igualdad de oportunidades y el fortalecimiento de la gobernanza institucional, garantizando una mejor orientación a los usuarios y contribuyendo al bienestar de la población mediante programas específicos en salud pública, gestión ambiental y desarrollo de medios de vida. La misión de la Municipalidad consiste en brindar servicios de calidad, promover el desarrollo local sostenible y la inclusión social en la provincia de Piura a través de una gobernanza efectiva, transparente, participativa y moderna, lo que requiere de herramientas de planificación que permitan anticipar las demandas ciudadanas y optimizar la asignación de recursos.

El marco legal que sustenta el proceso de formalización de la propiedad incluye normas de rango constitucional, legal y reglamentario que establecen las bases para la titulación de terrenos ocupados por posesiones informales. La Constitución Política del Perú reconoce el derecho de propiedad y establece los principios generales que rigen su ejercicio, mientras que el Código Civil desarrolla las disposiciones relativas a la propiedad, la posesión y los modos de adquirir el dominio. La Ley N° 31056, que amplía los plazos de la titulación de terrenos ocupados por posesiones informales y dicta medidas para la formalización, constituye una norma específica que busca acelerar

los procesos de regularización y brindar seguridad jurídica a los ocupantes de predios informales. Asimismo, la Ley N° 31079 modifica la Ley Orgánica de Municipalidades respecto de las municipalidades de centros poblados, mientras que la Ley N° 31433 modifica la Ley Orgánica de Municipalidades y la Ley Orgánica de Gobiernos Regionales en lo relativo a las atribuciones y responsabilidades de concejos municipales y consejos regionales, fortaleciendo su función de fiscalización. El Decreto Supremo N° 006-2006-Vivienda aprueba el Reglamento del Título I de la Ley N° 28687, referido a la formalización de la propiedad informal de terrenos ocupados por posesiones informales, centros urbanos informales y urbanizaciones populares, estableciendo los procedimientos técnicos y legales para la regularización. El Decreto Supremo N° 004-2019-JUS aprueba el Texto Único Ordenado de la Ley N° 27444, Ley del Procedimiento Administrativo General, que regula los procedimientos administrativos en el ámbito nacional. Complementariamente, la Resolución de Alcaldía N° 403-2005-A/MPP aprueba el Manual de Organización y Funciones de la Municipalidad Provincial de Piura, y el Decreto de Alcaldía N° 021-2022-A/MPP aprueba la Directiva N° 004-2022 denominada Lineamientos para la Formulación, Modificación y Aprobación de Directivas de la Municipalidad Provincial de Piura, estableciendo el marco normativo interno que regula el funcionamiento institucional.

Glosario de términos básicos y conceptos fundamentales para el análisis de series temporales y formalización de la propiedad

El análisis de series temporales y el proceso de formalización de la propiedad requieren el manejo de una terminología específica que permite una comunicación precisa entre los profesionales involucrados en estas áreas. En el ámbito del análisis de series temporales, la estacionalidad se refiere al patrón de comportamiento que se repite año a año o en intervalos fijos, mientras que la estacionariedad describe series que presentan media y varianza constante a lo largo del tiempo, es decir, que no siguen una tendencia sistemática. El MAPE (Mean Absolute Percent Error) constituye el error porcentual absoluto medio de un pronóstico, representando una métrica ampliamente utilizada para evaluar la precisión predictiva. Los outliers son valores atípicos o extremos en una muestra de datos que pueden distorsionar las estimaciones y requieren un tratamiento especial durante el análisis. La tendencia, por su parte, describe el patrón de comportamiento de una serie temporal a lo largo de una unidad de tiempo, reflejando movimientos sistemáticos de largo plazo. En el contexto de la formalización de la propiedad, la titulación constituye la etapa del proceso de legalización individual en la que se expide el instrumento de legalización correspondiente al destinatario que ha acreditado fehacientemente sus de-

rechos. La formalización de la propiedad comprende un conjunto de medidas legales, técnicas y de comunicación llevadas a cabo por organismos competentes en temas de saneamiento físico legal para combatir la informalidad de los derechos de propiedad urbana utilizando tecnologías modernas y procedimientos de formalización simplificados. El saneamiento físico legal es el procedimiento que, mediante acciones técnicas y legales ejecutadas directamente o a través de terceros, permite la continuación y conclusión de la formalización de la propiedad. La posesión informal se refiere a los asentamientos humanos, pueblos jóvenes, barrios marginales, barriadas, programas de vivienda municipales, centros poblados y toda otra forma de posesión, ocupación o titularidad informal de predios con fines urbanos. El poseedor o posesionario es la persona que posee un lote que forma parte de una posesión informal, centro urbano informal o urbanización popular con constancia de posesión extendida por la respectiva municipalidad. La calificación individual es la evaluación de documentos posterior a la presentación de un procedimiento administrativo, donde el titular presenta un certificado de la fecha de registro, cuyo objetivo es determinar si el reglamento cumple con los requisitos del Texto Único de Procedimiento Administrativo (TUPA) de la Municipalidad Provincial de Piura. La verificación constituye la diligencia en campo que tiene por objeto identificar la existencia de títulos u otro documento de

propiedad estén o no registrados a efectos de una eventual rectificación o actualización de datos para su inscripción ante Registros de Predios. La coposesión se produce cuando dos o más personas poseen conjuntamente el mismo bien, mientras que la copropiedad existe cuando un bien pertenece por cuotas ideales a dos o más personas, conforme a lo establecido en los artículos 899° y 969° del Código Civil, respectivamente.

Capítulo 3

Fundamentos metodológicos para el pronóstico de títulos de propiedad en la provincia de Piura

LA PROPIEDAD EN CIFRAS:
pronósticos estadísticos para la formalización urbana en Piura

Enfoque cuantitativo y diseño longitudinal para el análisis de series temporales

Esta investigación se enmarcó en un enfoque cuantitativo, ya que buscó determinar el comportamiento de una variable en el pasado para pronosticar su evolución futura, identificando el modelo que resultara más eficiente o de mayor precisión para el pronóstico de la variable en estudio. Este enfoque implicó obtener datos mediante procedimientos estadísticos para resolver problemas y se basó en mediciones objetivas y análisis numéricos, características que lo distinguen de los enfoques cualitativos centrados en la interpretación de significados y experiencias subjetivas (Fernández y Díaz, 2002). La elección de un enfoque cuantitativo resulta particularmente apropiada para el estudio de series temporales, ya que permite aplicar métodos estadísticos rigurosos para identificar patrones, estimar parámetros y evaluar la precisión de los modelos predictivos, ofreciendo resultados que pueden ser replicados y verificados mediante procedimientos estandarizados. El diseño de la investigación fue no experimental, porque el investigador registró los hechos tal como se presentaron en su contexto real, ya sea en un momento específico o a lo largo del tiempo, sin manipular deliberadamente las variables ni controlar las condiciones del estudio (Hernández et al., 2014). Esta característica resulta fundamental en el análisis de series temporales,

donde el investigador observa y registra los datos tal como ocurren naturalmente, sin intervenir en el proceso generador de los mismos. El estudio fue longitudinal, ya que utilizó datos de un período de 15 años, desde 2008 hasta 2023, lo que permitió examinar los procesos de cambio a lo largo del tiempo y capturar la evolución de la variable en estudio mediante métodos y técnicas cuantitativas para analizar fenómenos que requieren ser monitoreados a lo largo del tiempo (Caïs et al., 2014). La naturaleza longitudinal de la investigación es esencial para el análisis de series temporales, ya que proporciona la información histórica necesaria para identificar tendencias, estacionalidades y otros patrones que solo pueden ser observados cuando se dispone de un registro continuo y suficientemente extenso de los datos.

El nivel predictivo de la investigación se refirió a la capacidad de estimar la probabilidad de que ocurriera un evento dentro de una serie de sucesos, implicando el uso de modelos estadísticos y matemáticos para predecir el comportamiento futuro de una variable, basándose en patrones y tendencias históricas. Este nivel de análisis permitió a los investigadores generar pronósticos más precisos y tomar decisiones informadas sobre futuras acciones o estrategias, constituyendo el eje central de la investigación y el principal aporte al conocimiento y la práctica en el ámbito de la gestión pública. El tipo de estudio, tomando en cuenta a Bernal (2016), fue de tipo aplicado,

ya que la intención fue generar soluciones a interrogantes ya definidas con respuestas precisas a inquietudes minuciosas, lo que implica que los resultados obtenidos tienen un valor práctico inmediato y pueden ser utilizados directamente por los tomadores de decisiones en la Municipalidad Provincial de Piura. La población en estudio estuvo constituida por la cantidad de títulos de propiedad registrada de manera trimestral en la base de datos de la Municipalidad Provincial de Piura, y la muestra estuvo constituida por la cantidad de títulos de propiedad registrada de manera trimestral en la base de datos de la Municipalidad Provincial de Piura en el período de los años 2008 a 2023, asegurando así la representatividad de los datos y la validez de las inferencias realizadas a partir del análisis.

Procedimientos sistemáticos para la recolección, procesamiento y modelización de datos

Para obtener la información necesaria para la investigación, se solicitó a las autoridades municipales de la provincia de Piura que proporcionaran los datos requeridos, los cuales incluyeron el número de derechos inmobiliarios transferidos, desagregados en trimestres con el fin de permitir un análisis más detallado y capturar la estacionalidad intraanual de los procesos de titulación. A partir de dicha información, se procedió a la creación de una base de datos específicamente diseñada para este

proyecto, paso que resultó fundamental, ya que contar con datos precisos y bien estructurados fue esencial para la elaboración de pronósticos confiables y útiles. La base de datos resultante fue utilizada en el análisis, en el cual se aplicaron diversos métodos y modelos estadísticos con el objetivo de predecir la futura transferencia de derechos inmobiliarios en la provincia de Piura, asegurando que las previsiones obtenidas fueran lo más precisas y valiosas posible, proporcionando información clave para la toma de decisiones y la planificación del patrimonio. La adecuada recopilación y preparación de los datos garantizó que el análisis posterior se basara en información confiable y consistente, minimizando los riesgos de sesgos o errores que pudieran comprometer la validez de los resultados obtenidos (Hyndman & Athanasopoulos, 2021; Chatfield, 2019). Los datos extraídos fueron procesados utilizando aplicaciones estadísticas avanzadas, como Python y R, que permitieron realizar un análisis detallado y preciso, además de facilitar su transformación y preparación para la siguiente etapa del proceso. La información fue organizada en marcos de datos, sobre los cuales se aplicaron diversas herramientas de análisis de series de tiempo con el propósito de identificar patrones, tendencias, estacionalidad y estacionariedad en la serie correspondiente a los títulos de propiedad entregados en la provincia de Piura, incluyendo la ejecución de pruebas de hipótesis necesarias para verificar los supuestos requeridos en el estudio de series temporales.

A continuación, se determinaron los componentes óptimos de los modelos de Holt-Winters para el pronóstico, y se evaluaron los parámetros más adecuados para los modelos de Box-Jenkins. En el caso del modelo ARIMA, se identificaron los valores óptimos de los parámetros: p (orden autorregresivo), d (grado de diferenciación) y q (orden de media móvil), mientras que para el modelo SARIMA, además de los parámetros mencionados, se determinaron los componentes estacionales P , D , Q y m (número de períodos por temporada). La identificación de estos parámetros se llevó a cabo mediante el análisis de los gráficos de autocorrelación (ACF) y autocorrelación parcial (PACF), así como mediante pruebas de estacionariedad, que permitieron determinar el grado de diferenciación necesario para lograr la estacionariedad de la serie (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). Posteriormente, los modelos fueron evaluados utilizando los criterios de información AIC y BIC, con el fin de seleccionar la mejor combinación entre ajuste y complejidad, considerando preferibles aquellos modelos que presentaron los valores más bajos de estos indicadores (Burnham & Anderson, 2019; Schwarz, 1978). Finalmente, se llevó a cabo un análisis integral del desempeño de los modelos de series de tiempo utilizados en el estudio, incluyendo medidas de precisión y calidad del ajuste, tales como el Error Cuadrático Medio (MSE), el Error Absoluto Medio (MAE) y el Coeficiente de Determinación (R^2). Todos los

modelos desarrollados fueron comparados con el objetivo de identificar cuál ofrecía los resultados más óptimos en función de los datos históricos, considerando también la capacidad de los modelos para capturar patrones estacionales y tendencias a largo plazo, así como su resiliencia frente a posibles anomalías en los datos. El análisis de estos indicadores permitió seleccionar el modelo más efectivo y eficiente, no solo en términos técnicos, sino también en cuanto a su aplicabilidad práctica para pronosticar la cantidad de títulos de propiedad entregados en la provincia de Piura durante el período 2024-2025, asegurando que el modelo seleccionado proporcionara predicciones precisas y útiles para la toma de decisiones (Makridakis et al., 2020; Petropoulos et al., 2022).

Técnicas de recolección de datos, instrumentos y consideraciones éticas en la investigación

Se utilizó como técnica la consulta electrónica, que permitió acceder de manera eficiente y sistemática a las bases de datos administrativas de la Municipalidad Provincial de Piura, garantizando la obtención de información actualizada y verificable. Como herramienta de recolección de datos, se empleó una hoja de cálculo de Excel, en la cual se realizó la recopilación de análisis extraídos de las bases de datos de la Municipalidad Provincial de Piura (fuente directa). Este instrumento permitió organi-

zar la información de manera estructurada, facilitando su posterior procesamiento y análisis mediante aplicaciones estadísticas especializadas. La investigación enfatizó la importancia de la ética en la investigación, destacando la seriedad con la que se debieron tratar las referencias citadas, en particular aquellas de autores reconocidos en el campo de estudio, práctica que aseguró una transparencia indiscutible en el manejo de la información, crucial para mantener la integridad y la credibilidad del trabajo académico. Asimismo, se destacó que asegurar la originalidad del proyecto fue fundamental para evitar el plagio, lo que se logró mediante un escrupuloso proceso de verificación de fuentes y referencias, respaldado con una declaración de autenticidad tanto del autor como del asesor, certificando no solo la originalidad del trabajo, sino también reforzando el compromiso ético y profesional de todos los involucrados en la investigación (Morales, 2017). Estos principios éticos son fundamentales en toda investigación académica, ya que garantizan que los resultados obtenidos sean confiables y que el conocimiento generado contribuya de manera significativa al avance de la disciplina y a la solución de problemas prácticos en la sociedad.

Capítulo 4

*Análisis de resultados y evaluación de modelos
predictivos para la entrega de títulos de propiedad*

LA PROPIEDAD EN CIFRAS:
pronósticos estadísticos para la formalización urbana en Piura

Caracterización descriptiva y comportamiento histórico de la serie temporal

El análisis exploratorio de datos constituyó la primera etapa fundamental para comprender las características y patrones de comportamiento de los datos antes de aplicar cualquier modelo predictivo, permitiendo identificar tendencias, estacionalidades y anomalías en la entrega de títulos de propiedad en la provincia de Piura. La serie temporal, compuesta por 64 observaciones trimestrales correspondientes al período 2008-2023, presentó una media de 160.43 títulos entregados por trimestre, con una mediana de 157 que indica una distribución relativamente simétrica. La desviación estándar de 83.6 reveló una variabilidad considerable en los datos, con un rango que se extendió desde un mínimo de 23 hasta un máximo de 351 títulos, reflejando la heterogeneidad en la actividad de titulación a lo largo del período analizado. El análisis de percentiles mostró que el 25% de los títulos entregados se situó por debajo de las 96 unidades, mientras que el 75% estuvo por debajo de los 211 títulos, indicando una distribución con cierta concentración en valores intermedios y una cola hacia valores más altos. La tendencia general de la serie evidenció un comportamiento creciente, lo que sugiere un incremento en el número de títulos de propiedad emitidos con el tiempo, reflejando posiblemente una mejora en la gestión y distribución de títulos en la

región, asociada a políticas gubernamentales más efectivas o a una mayor demanda de regularización de propiedades por parte de los pobladores (Herrera et al., 2022; Albán, 2023).

El análisis de normalidad mediante la prueba de Shapiro-Wilk arrojó un valor de significancia de 0.1002, superior al nivel teórico de 0.05, lo que permitió inferir que no existe evidencia suficiente para rechazar la hipótesis nula de normalidad. Este resultado sugiere que las variaciones en la entrega de títulos de propiedad siguen un patrón predecible y que las herramientas estadísticas que asumen normalidad pueden ser aplicadas de manera adecuada para analizar estos datos (Fernández y Díaz, 2002; Hernández et al., 2014). El gráfico Q-Q corroboró este hallazgo al mostrar que los puntos de los datos se encuentran cercanos a la línea diagonal, indicando una baja desviación de la normalidad y aumentando la confiabilidad de los resultados obtenidos al aplicar métodos estadísticos que asumen una distribución normal. Esta característica resulta particularmente valiosa para realizar inferencias y predicciones más precisas sobre la entrega de títulos de propiedad en la región, ya que los modelos estadísticos basados en el supuesto de normalidad tienden a ofrecer estimaciones más estables y confiables cuando este supuesto se cumple satisfactoriamente (Hyndman & Athanasopoulos, 2021; Chatfield, 2019).

Descomposición de la serie temporal e identificación de componentes estructurales

Para identificar patrones, tendencias y estacionalidades en la entrega de títulos de propiedad en la provincia de Piura, se realizó una descomposición de la serie temporal en tres componentes fundamentales: tendencia, estacionalidad y residuos, lo que permitió obtener una visión clara y detallada de cada uno de estos aspectos. La serie original mostró fluctuaciones importantes a lo largo del período analizado, con picos notables alrededor de 2018 y 2023, y un valle pronunciado en 2010 con solo 27 títulos entregados, indicando una baja significativa en la actividad de entrega de títulos durante ese período. La tendencia general, representada por una línea cian discontinua, evidenció una dirección al alza a lo largo del tiempo, sugiriendo un incremento sostenido en el número de títulos de propiedad entregados, lo que además proporciona evidencias de que la serie no es estacionaria, característica que debe ser abordada mediante técnicas de diferenciación antes de aplicar modelos predictivos (Shumway & Stoffer, 2017; Brockwell & Davis, 2016). La estacionalidad, mostrada con una línea roja discontinua, capturó los patrones repetitivos y predecibles dentro de cada año, indicando que hay ciertos trimestres en los que se entregan consistentemente más títulos de propiedad, lo que podría estar asociado a ciclos presupuestales, fechas

clave en el calendario administrativo o factores estacionales que afectan la demanda de regularización de propiedades (Makridakis et al., 2020; Petropoulos et al., 2022).

La prueba de Dickey-Fuller aumentada (ADF) aplicada a la serie original arrojó un valor de significancia de 0.703, superior al nivel teórico de 0.05, lo que condujo a aceptar la hipótesis nula de que la serie presenta una raíz unitaria y, por consiguiente, no es estacionaria. Este resultado evidenció la necesidad de analizar las primeras diferencias de los datos para garantizar la estacionariedad antes de continuar con el análisis y modelado de la serie temporal. Al aplicar la prueba ADF a la primera diferencia de la serie, se obtuvo un valor de significancia de 0.037, inferior al nivel teórico de 0.05, lo que permitió rechazar la hipótesis nula y concluir que la serie diferenciada es estacionaria. Este hallazgo resultó crucial porque la estacionariedad de la serie permite utilizar modelos de series temporales con mayor precisión y confianza, facilitando la predicción y el análisis de tendencias futuras al saber que las fluctuaciones en la entrega de títulos de propiedad son consistentes a lo largo del tiempo (Hyndman & Koehler, 2006; Wei, 2018). Este resultado proporcionó una base sólida para entender y anticipar mejor el comportamiento de la entrega de títulos en la región, estableciendo las condiciones necesarias para la aplicación de modelos ARIMA y SARIMA que requieren estacionariedad como supuesto fundamental (Box et al., 2015; Ljung & Box, 2018).

Optimización y selección del modelo Holt-Winters para el pronóstico de títulos de propiedad

Para determinar los componentes óptimos del modelo Holt-Winters para los títulos de propiedad entregados por la municipalidad de Piura, se analizaron los modelos aditivo y multiplicativo basados en el comportamiento de los datos, ajustando los parámetros de suavizado (nivel, tendencia y estacionalidad) mediante técnicas de optimización que buscaron minimizar las métricas de error. El modelo aditivo de Holt-Winters presentó tres configuraciones con diferentes parámetros de suavizado, evaluadas mediante el Error Absoluto Medio (MAE), el Error Cuadrático Medio (MSE), el Error Porcentual Absoluto Medio (MAPE) y el coeficiente de determinación R^2 . La configuración óptima, caracterizada por un Alpha (α) de 0.9587 que indica un peso predominante a las observaciones más recientes para estimar el nivel, un Gamma (γ) de 0.0002 que sugiere una tendencia muy estable con poca influencia de las observaciones pasadas, y un Delta (δ) de 0.034 que refleja un componente estacional que cambia lentamente, ofreció los mejores indicadores de desempeño. Este modelo presentó el menor MAE (34.678), el menor MSE (2121.32) y el mayor R^2 (0.692), lo que indica que ofrece una precisión y fiabilidad superiores en comparación con otras configuraciones, demostrando su capacidad para

capturar adecuadamente los patrones de comportamiento de la serie temporal (Gardner, 2019; Taylor, 2020).

La comparación entre las diferentes configuraciones del modelo Holt-Winters aditivo reveló que la elección de los parámetros de suavizado tiene un impacto significativo en el desempeño predictivo del modelo. La segunda configuración, con $\alpha=0.9595$, $\gamma=0.0001$ y $\delta=0.0001$, presentó un MAE de 35.76 y un MSE de 2136.87, mientras que la tercera configuración, con $\alpha=0.9226$, $\gamma=0.0084$ y $\delta=0.0522$, alcanzó un MAE de 35.13 y un MSE de 2158.69, confirmando la superioridad de la primera configuración en todas las métricas evaluadas (Hyndman & Athanassopoulos, 2021; Makridakis et al., 2020). El MAPE del modelo seleccionado fue de 26.86%, indicando que el error porcentual promedio de los pronósticos se mantiene en niveles aceptables para el contexto de gestión pública. El R^2 de 0.692 sugiere que aproximadamente el 69% de la variabilidad en la entrega de títulos de propiedad puede ser explicada por el modelo, lo que representa un nivel de ajuste moderado pero significativo considerando la complejidad de los factores que influyen en el proceso de titulación (Chai & Draxler, 2014; Willmott & Matsuura, 2019). La literatura especializada ha documentado que valores de R^2 en este rango son comunes en aplicaciones de pronóstico de indicadores de gestión pública, donde múltiples factores no modelados pueden influir en el

comportamiento de la variable (Armstrong, 2020; Fildes & Goodwin, 2021).

El modelo puede expresarse matemáticamente como:
Ecuación de Nivel (ℓ_t):

$$\ell_t = 0.9587(y_t - S_{t-4}) + (0.0413) (\ell_{t-1} + b_{t-1})$$

Ecuación de Tendencia (b):

$$b_t = 0.0002(\ell_t - \ell_{t-1}) + (0.9998) b_{t-1}$$

Ecuación de Estacionalidad (s):

$$S_t = 0.034(y_t - \ell_{t-1} - b_{t-1}) + 0.966$$

Ecuación de Predicción ($\hat{y}$):

$$\hat{y}_{T+k|T} = \ell_T + kb_T + S_{T+k-4(h+1)}$$


Una vez determinados los parámetros óptimos del modelo aditivo de Holt-Winters, se procede a corroborar los supuestos para el modelo de pronósticos de los títulos de propiedad entregados en la provincia de Piura durante el periodo 2008-2023. Este proceso de validación es fundamental para asegurar la fiabilidad y precisión del modelo predictivo antes de su implementación en la toma de decisiones.

Evaluación del modelo Holt-Winters aditivo y selección del modelo multiplicativo óptimo

Ajuste del modelo aditivo y verificación de supuestos para la serie de títulos de propiedad

La serie de tiempo correspondiente a los títulos de propiedad entregados en la provincia de Piura entre 2008 y 2023 fue sometida a un proceso de modelización mediante el enfoque aditivo de Holt-Winters. En esta representación gráfica, la línea azul discontinua muestra los datos originales, mientras que la línea roja continua exhibe los valores ajustados por el modelo, observándose una proximidad significativa entre ambas trayectorias que evidencia la capacidad del modelo para capturar adecuadamente las fluctuaciones, las variaciones estacionales y la tendencia general de la serie. El modelo aditivo demuestra un ajuste satisfactorio, como lo confirma la cercanía entre las líneas, lo que indica que las estimaciones generadas son confiables para pronosticar futuros valores de títulos de propiedad entregados. Esta buena alineación entre los datos observados y los valores ajustados sugiere que las predicciones futuras serán precisas y útiles para la toma de decisiones, proporcionando a las autoridades municipales información valiosa para la planificación y asignación de recursos en el proceso de titulación.

Figura 1. Ajuste Holt-Winters de títulos de propiedad en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Para evaluar la validez del modelo aditivo de Holt-Winters, resulta esencial verificar los supuestos de normalidad de los residuos, que constituyen las diferencias entre los valores observados y los valores ajustados del modelo. La prueba de Shapiro-Wilk aplicada a los residuos del modelo aditivo arrojó un valor de significancia de 0.0565, superior al nivel teórico de 0.05, lo que permitió inferir que los residuos pueden considerarse como provenientes de una distribución normal, sugiriendo que el modelo de pronóstico Holt-Winters aditivo es adecuado para los datos analizados. La confirmación de la normalidad de los residuos valida la fiabilidad del modelo Holt-Winters aditivo para realizar pronósticos precisos, ya que el cumplimiento de este supuesto garantiza que las inferencias estadísticas basadas en el modelo sean confia-


bles y que los intervalos de confianza contruidos a partir de los pronósticos tengan la cobertura esperada. El gráfico Q-Q de los residuos muestra que los puntos se encuentran cercanos a la línea diagonal, reforzando visualmente la conclusión de que los residuos pueden ser tratados como normalmente distribuidos en los análisis posteriores. Este resultado resulta particularmente relevante porque la normalidad de los residuos es un indicador de que el modelo ha capturado adecuadamente la estructura sistemática de los datos, dejando únicamente fluctuaciones aleatorias que no presentan patrones discernibles.

Tabla 1. Evaluación de normalidad de residuos del modelo Holt-Winters

Prueba de Shapiro-Wilk	
Estadístico	0.953
gl	64
Sig.	0.0565

Nota: Amaya Paiva & Farfan Morales (2025).

Figura 2. Análisis de Gráfico Q-Q de Títulos de Propiedad Entregados en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Optimización y selección del modelo multiplicativo de Holt-Winters para el pronóstico

Para determinar los componentes óptimos del modelo multiplicativo de Holt-Winters, se evaluaron tres configuraciones con diferentes parámetros de suavizado para el nivel (α), la pendiente (γ) y la estacionalidad (δ), que satisfacen la condición $0 \leq \alpha, \gamma, \delta \leq 1$, comparando su desempeño mediante las métricas MAE, MSE, MAPE y R^2 . Los parámetros de suavizado y las métricas de error del modelo Holt-Winters multiplicativo para las diferentes configuraciones revelaron que la tercera configuración, caracterizada por $\alpha=0.774$, $\gamma=0.0129$ y $\delta=0.0428$, ofreció los mejores indicadores de desempeño con un MAE de 38.05, un MSE de 2424.01 y un R^2 de 0.648. Este modelo

superó a las otras configuraciones evaluadas, demostrando su superioridad en la captura de la estructura temporal de los datos. El MAPE del modelo seleccionado fue de 34.03%, ligeramente superior al del modelo aditivo, lo que sugiere que para esta serie temporal el enfoque aditivo podría ofrecer una precisión porcentual ligeramente mejor, aunque el modelo multiplicativo captura de manera más adecuada la variabilidad proporcional de los datos.

Tabla 2. Parámetros de suavizado Holt-Winters multiplicativo

Modelo Multiplicativo de Holt Winters			
Métricas	(α) = 0.688	(α) = 0.8229	(α) = 0.774
	(Y) = 0.0001	(Y) = 0.0217	(Y) = 0.0129
	(S) = 0.441	(S) = 0.0001	(S) = 0.0428
MAE	42.111	38.22	38.05
MSE	3192.459	2441.386	2424.01
MAPE	30.55%	34.19%	34.03%
R2 Core	0.536	0.645	0.648

Nota: Amaya Paiva & Farfan Morales (2025).

La comparación entre los modelos aditivo y multiplicativo de Holt-Winters revela diferencias significativas en su capacidad para ajustarse a los datos y generar pronósticos precisos. El modelo aditivo seleccionado presentó un MAE de 34.678, un MSE de 2121.32 y un R^2 de 0.692, superando al modelo multiplicativo en todas las métricas evaluadas, lo que sugiere que el enfoque aditivo es más adecuado para esta serie temporal específica. Esta dife-

rencia puede atribuirse a que los patrones estacionales en la entrega de títulos de propiedad tienden a mantener una magnitud constante a lo largo del tiempo, independientemente del nivel general de la serie, lo que favorece el enfoque aditivo sobre el multiplicativo. La literatura especializada ha documentado que la elección entre modelos aditivos y multiplicativos debe basarse en las características específicas de los datos, recomendando el enfoque aditivo cuando la magnitud de las fluctuaciones estacionales no varía con el nivel de la serie, como parece ser el caso de la entrega de títulos de propiedad en la provincia de Piura. El R^2 de 0.692 para el modelo aditivo indica que aproximadamente el 69% de la variabilidad en la entrega de títulos de propiedad puede ser explicada por el modelo, lo que representa un nivel de ajuste moderado pero significativo para un fenómeno complejo influenciado por múltiples factores administrativos, políticos y sociales.

El modelo puede expresarse matemáticamente como:

Ecuación Nivel (ℓ_t):

$$\ell_t = 0.774 \left(\frac{y_t}{S_{t-4}} \right) + 0.226(\ell_{t-1} + b_{t-1})$$

Ecuación de Tendencia (b_t):

$$b_t = 0.0129(\ell_t - \ell_{t-1}) + 0.9871b_{t-1}$$

Ecuación de Estacionalidad (s):

$$S_t = 0.0428 \left(\frac{y_t}{\ell_{t-1} - b_{t-1}} \right) + 0.9572 S_{t-4}$$

Ecuación de Predicción ($\hat{y}$):

$$\hat{y}_{t+k|t} = (\ell_t + k b_1) S_{t-4(h+1)}$$


Evaluación del modelo Holt-Winters multiplicativo y selección del modelo ARIMA óptimo

Ajuste del modelo multiplicativo y verificación de supuestos para la serie de títulos de propiedad

La serie de tiempo correspondiente a los títulos de propiedad entregados en la provincia de Piura entre 2008 y 2023 fue sometida a un proceso de modelización mediante el enfoque multiplicativo de Holt-Winters. En esta representación gráfica, la línea azul discontinua muestra los datos originales, mientras que la línea roja continua exhibe los valores ajustados por el modelo, observándose una proximidad moderada entre ambas trayectorias que evidencia la capacidad del modelo para capturar parcialmente las fluctuaciones, las variaciones estacionales y la tendencia general de la serie. El modelo multiplicativo demuestra un ajuste medianamente satisfactorio, lo que indica que las estimaciones generadas son parcialmente confiables para pronosticar futuros valores de títulos de propiedad entregados, aunque con limitaciones que de-

ben ser consideradas en la interpretación de los resultados. Esta alineación intermedia entre los datos observados y los valores ajustados sugiere que las predicciones futuras podrían presentar cierto grado de imprecisión, por lo que se recomienda complementar el análisis con otros enfoques metodológicos que permitan validar y refinar las proyecciones obtenidas.

Figura 3. Valores ajustados Holt-Winters multiplicativo de títulos en Piura 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Para evaluar la validez del modelo multiplicativo de Holt-Winters, resulta esencial verificar los supuestos de normalidad de los residuos, que constituyen las diferencias entre los valores observados y los valores ajustados del modelo. La prueba de Shapiro-Wilk aplicada a los residuos del modelo multiplicativo arrojó un valor de signi-


ficancia de 0.0001, inferior al nivel teórico de 0.05, lo que permitió inferir que los residuos no pueden considerarse como provenientes de una distribución normal, sugiriendo que el modelo de pronóstico Holt-Winters multiplicativo no es adecuado para los datos analizados. La confirmación de la no normalidad de los residuos cuestiona la fiabilidad del modelo Holt-Winters multiplicativo para realizar pronósticos precisos, ya que el incumplimiento de este supuesto afecta la validez de las inferencias estadísticas basadas en el modelo y compromete la confiabilidad de los intervalos de confianza construidos a partir de los pronósticos. El gráfico Q-Q de los residuos muestra que los puntos se desvían significativamente de la línea diagonal, reforzando visualmente la conclusión de que los residuos no pueden ser tratados como normalmente distribuidos en los análisis posteriores. Este resultado resulta particularmente relevante porque la falta de normalidad de los residuos es un indicador de que el modelo no ha capturado adecuadamente la estructura sistemática de los datos, dejando patrones discernibles que podrían ser modelados mediante enfoques alternativos.

Tabla 3. Normalidad de residuos del modelo Holt-Winters multiplicativo

Prueba de Shapiro-Wilk	
Estadístico	0.907
gl	64
Sig.	0.0001

Nota: Amaya Paiva & Farfan Morales (2025).

Figura 4. Gráfico Q-Q de títulos entregados en Piura, 2008-2023




Nota: Amaya Paiva & Farfan Morales (2025).

Identificación y selección de parámetros óptimos para el modelo ARIMA

Para evaluar los parámetros óptimos del modelo ARIMA, se presenta el correlograma de la primera diferencia de títulos de propiedad entregados en la provincia de Piura, el cual se utiliza para determinar la presencia de correlaciones en los rezagos de la serie temporal, lo que resulta crucial para la selección de los órdenes apropiados de los componentes AR y MA del modelo. El correlograma presentado consta de dos gráficos fundamentales en el análisis de series temporales: la Función de Autocorrelación (ACF) y la Función de Autocorrelación Parcial (PACF). En la ACF, se observan picos significativos en los rezagos 1, 2, 3, 4, 5, 7, 8 y 9, lo que sugiere una autocorrelación positiva en estos puntos, mientras que a partir

del rezago 10 las autocorrelaciones disminuyen gradualmente, indicando un patrón persistente en la serie temporal pero con una disminución gradual en la influencia de observaciones pasadas. En la PACF, se identifican picos significativos en los rezagos 1, 3 y 4, eliminando el efecto de rezagos intermedios, mientras que a partir del rezago 5 las autocorrelaciones parciales disminuyen rápidamente, indicando que los primeros rezagos tienen una influencia directa significativa sobre los valores futuros de la serie temporal.

Figura 5. Correlograma de la primera diferencia de títulos en Piura, 2024-2025



Nota: Amaya Paiva & Farfan Morales (2025).

La determinación de la diferenciación, basada en los resultados de la prueba ADF presentados anteriormente,

indica que al aplicar la primera diferencia a la serie temporal de títulos de propiedad otorgados en la provincia de Piura se suprime la existencia de una raíz unitaria, señalando que la serie es estacionaria. Para determinar los parámetros apropiados de un modelo ARIMA empleando las funciones de autocorrelación y autocorrelación parcial, se examina el correlograma, observándose que los retrasos significativos en la ACF fueron 4 lags, por lo que se concluye que $q=4$, mientras que en la PACF se observaron 3 lags significativos, por lo que se concluye que $p=3$. La selección del modelo se realizó mediante los criterios de información AIC y BIC, probando diferentes combinaciones de p , d y q , y seleccionando el modelo con los valores más bajos de estos indicadores. Los resultados muestran que el modelo con los valores AIC y BIC más bajos es aquel con $p=3$, $d=1$, $q=3$, presentando un AIC de 689.45 y un BIC de 704.45, lo que sugiere que este modelo es el mejor en términos de ajustar los datos con la menor complejidad. El AIC de 689.45 indica que este modelo tiene el mejor equilibrio entre ajuste y complejidad comparado con otros modelos probados, mientras que el BIC de 704.45, que penaliza más por la cantidad de parámetros utilizados, también sugiere que este modelo es preferible porque no solo ajusta bien los datos, sino que también es relativamente simple.

Tabla 4. Parámetros óptimos ARIMA por criterio de selección

ARIMA							
Criterio de Selección	$p = 0$	$p = 0$	$p = 1$	$p = 1$	$p = 1$	$p = 2$	$p = 3$
	$d = 1$	$d = 1$	$d = 1$	$d = 1$	$d = 1$	$d = 1$	$d = 1$
	$q = 2$	$q = 3$	$q = 2$	$q = 3$	$q = 4$	$q = 3$	$q = 3$
AIC	730.45	728	708.33	696.39	698.37	698.37	689.45
BIC	736.92	736.58	716.9	707.105	711.23	711.22	704.45

Nota: Amaya Paiva & Farfan Morales (2025).

Evaluación y selección final del modelo ARIMA para el pronóstico de títulos de propiedad

El modelo ARIMA (3,1,3) propuesto se basa en la interpretación del correlograma y de los criterios AIC y BIC, donde $p=3$ indica que tres rezagos son significativos en la PACF, $d=1$ señala que la serie necesita ser diferenciada una vez para ser estacionaria, y $q=3$ indica que tres rezagos en la ACF son significativos. Este modelo demuestra ser óptimo para la serie temporal de títulos de propiedad en Piura, ya que aplicar la primera diferencia garantiza la estacionariedad de la serie eliminando la raíz unitaria, mientras que los parámetros $p=3$, $d=1$ y $q=3$ se determinan mediante el análisis de ACF, PACF y la prueba de Dickey-Fuller. El modelo captura la dependencia de los últimos tres rezagos en valores pasados (AR) y errores de pronóstico (MA), y los valores de AIC (689.45) y BIC (704.45) indican un buen equilibrio entre precisión y complejidad. Para asegurar la precisión y validez del mo-

delo ARIMA, se evaluaron tres modelos con los valores AIC y BIC más bajos, considerando las métricas de error MSE, MAPE y MAE para evaluar el rendimiento del modelo, garantizando un buen ajuste a los datos históricos y alta capacidad predictiva. La comparación de los modelos ARIMA con diferentes parámetros revela que el modelo ARIMA (3,1,3) presenta el mejor desempeño con un MAE de 38.44, un MSE de 2558.44, un MAPE de 33.29% y un R² de 0.63, superando a las configuraciones ARIMA (1,1,3) y ARIMA (2,1,3) en todas las métricas evaluadas. Los coeficientes del modelo ARIMA (3,1,3) muestran valores significativos para cada retardo, con desviaciones estándar que respaldan la estabilidad de las estimaciones y la confiabilidad del modelo para generar pronósticos precisos de la entrega de títulos de propiedad en la provincia de Piura.

Tabla 5. Comparación de Modelos ARIMA con Diferentes Parámetros

ARIMA			
Métricas	$p = 1$	$p = 2$	$p = 3$
	$d = 1$	$d = 1$	$d = 1$
	$q = 3$	$q = 3$	$q = 3$
MAE	41.76	41.82	38.44
MSE	3063.1	3061.53	2558.44
MAPE	37.62%	37.5%	33.29%
R2 Core	0.554	0.555	0.63

Nota: Amaya Paiva & Farfan Morales (2025).

Tabla 6. Coeficientes del Modelo ARIMA

		Coeficiente	SE
AR	Retardo 1	-1.0359	0.064
	Retardo 2	-1.0358	0.066
	Retardo 3	-0.9999	0.002
Diferencia		1	
MA	Retardo 1	1.0262	0.321
	Retardo 2	1.0265	0.17
	Retardo 3	0.9997	0.204

Nota: Amaya Paiva & Farfan Morales (2025).

El modelo puede expresarse matemáticamente como:

$$(1 + 1.0359L + 1.0358L^2 + 0.9999L^3)(1 - L)Y_t = (1 - 1.0262L - 1.0265L^2 - 0.9997L^3)\epsilon_t$$

Donde:

L es el operador de rezago. Componente AR (Autorregresivo):

$\phi_1 = -1.0359$: Indica el efecto de la dependencia lineal entre la observación actual y su valor inmediatamente anterior.

$\phi_2 = -1.0358$: Representa la dependencia lineal con la segunda observación anterior.

$\phi_3 = -0.9999$: Indica la dependencia lineal con la segunda observación anterior.

Componente I (Integrado):

$d = 1$: Una diferencia.

Componente MA (Media Móvil):

$\phi_1 = 1.0262$: Describe el efecto de la media móvil en el error actual y su relación con los errores pasados.

$\phi_2 = 1.0265$: Indica la relación con el segundo término de la media móvil.


$\phi_3 = 0.9997$: Describe la relación con el tercer término de la media móvil.

Validación del modelo ARIMA y propuesta del modelo SARIMA para el pronóstico de títulos de propiedad*Validación del modelo ARIMA y verificación de supuestos de normalidad*

Una vez determinados los parámetros óptimos del modelo ARIMA, se lleva a cabo un proceso riguroso de validación para corroborar los supuestos del modelo de pronósticos de los títulos de propiedad entregados en la provincia de Piura durante el período 2008-2023, paso crucial para garantizar que el modelo sea confiable y preciso antes de su implementación en la toma de decisiones. La Figura 10 presenta los valores ajustados del modelo

ARIMA (3,1,3) para los títulos de propiedad entregados en la provincia de Piura entre 2008 y 2023, revelando una notable congruencia entre los valores reales, representados por la línea azul punteada, y las predicciones ajustadas del modelo, mostradas con la línea roja continua. Esta alineación precisa indica que el modelo ARIMA ha capturado efectivamente las fluctuaciones y patrones presentes en los datos históricos, subrayando su fiabilidad para realizar predicciones futuras, lo que resulta esencial para planificar estrategias efectivas basadas en datos históricos sólidos y modelos predictivos confiables. La validación del modelo a través de métricas como MSE, MAPE y MAE confirma su precisión y robustez, consolidándolo como una herramienta fundamental para la toma de decisiones en políticas de vivienda y desarrollo urbano en Piura, ya que la precisión en la predicción es esencial para anticipar la demanda de titulación y asignar eficientemente los recursos disponibles.

Figura 6. Valores ajustados del ARIMA(3,1,3) para títulos en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Para evaluar la validez del modelo ARIMA, resulta fundamental verificar que los residuos, es decir, las diferencias entre los valores observados y los valores ajustados, sigan una distribución normal, asegurando que el modelo ha capturado adecuadamente las dependencias en los datos y que los errores restantes son aleatorios y no estructurados. La prueba de Shapiro-Wilk aplicada a los residuos del modelo ARIMA arrojó un valor de significancia de 0.0582, superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de normalidad, permitiendo inferir que los residuos pueden considerarse como provenientes de una distribución normal, sugiriendo que el modelo de pronóstico ARIMA (3,1,3) es adecuado para los datos analizados. La Figura 11, correspondiente al gráfico Q-Q de los resi-


duos, muestra que los puntos se encuentran cercanos a la línea diagonal, reforzando visualmente la conclusión de que los residuos pueden ser tratados como normalmente distribuidos en los análisis posteriores. La confirmación de la normalidad de los residuos valida la fiabilidad del modelo ARIMA (3,1,3) para realizar pronósticos precisos, ya que el cumplimiento de este supuesto garantiza que las inferencias estadísticas basadas en el modelo sean confiables y que los intervalos de confianza construidos a partir de los pronósticos tengan la cobertura esperada (Box et al., 2015; Wei, 2018). Este resultado resulta particularmente relevante porque la normalidad de los residuos es un indicador de que el modelo ha capturado adecuadamente la estructura sistemática de los datos, dejando únicamente fluctuaciones aleatorias que no presentan patrones discernibles (Ljung & Box, 2018; McLeod et al., 2019).

Tabla 7. Normalidad de residuos del modelo ARIMA

Prueba de Shapiro-Wilk	
Estadístico	0.958
gl	64
Sig.	0.0582

Nota: Amaya Paiva & Farfan Morales (2025).

Figura 7. Gráfico Q-Q de residuos del modelo ARIMA para títulos en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Identificación y selección de parámetros óptimos para el modelo SARIMA

Después de revisar el modelo ARIMA y sus respectivos supuestos, y de analizar el correlograma presentado en la figura anterior, se identificó la necesidad de incorporar componentes estacionales en el pronóstico de los títulos de propiedad de la Municipalidad Provincial de Piura, proponiendo implementar un modelo SARIMA para capturar la estacionalidad en los datos, mejorando la precisión y fiabilidad del pronóstico. Para optimizar los parámetros del modelo SARIMA, se utilizó software estadístico especializado como R y Python, ajustando y validando los parámetros de estacionalidad y no estacionalidad para

obtener pronósticos más precisos y fiables, proceso que aseguró que el modelo capture de manera adecuada las tendencias y patrones estacionales en los datos. La determinación de la diferenciación no estacional (d) se basó en los resultados de la prueba ADF presentados anteriormente, indicando que al aplicar la primera diferencia a la serie temporal de títulos de propiedad entregados en la provincia de Piura se elimina la presencia de una raíz unitaria, lo cual indica que la serie es estacionaria. Para evaluar la estabilidad de los patrones estacionales en series temporales se aplicó la prueba de Canova-Hansen, que examina la presencia de raíces unitarias en las frecuencias estacionales, donde la hipótesis nula establece que la estacionalidad del proceso es de tipo determinista, es decir, que los patrones estacionales son constantes a lo largo del tiempo. La prueba de Canova-Hansen arrojó un valor de significancia de 0.045, inferior al nivel teórico de 0.05, lo que llevó a rechazar la hipótesis nula e indicar que la serie temporal es no determinista, resultando necesario aplicar la diferenciación en la parte estacionaria para estabilizar la serie. Mediante la aplicación de la prueba de Canova-Hansen utilizando software estadístico en Python, se obtuvo que el número de diferenciaciones estacionales necesarias para lograr que la serie sea estacionaria es 1, concluyendo que es necesario aplicar una diferenciación en la parte estacional de la serie temporal para lograr que esta sea estacionaria, análisis crucial para

eliminar los patrones estacionales y asegurar la estabilidad de la serie, lo cual es fundamental para realizar modelos precisos y confiables.

Tabla 8. Prueba de Canova-Hansen para la primera diferencia de la serie

Prueba Canova-Hansen	
Estadístico	1.268
Sig.	0.045

Nota: Amaya Paiva & Farfan Morales (2025).

Tabla 9. Número de Diferencias Estacionales

Prueba Canova-Hansen	
Número de diferenciaciones estacionales necesarias	1

Nota: Amaya Paiva & Farfan Morales (2025).

Evaluación y selección final del modelo SARIMA para el pronóstico de títulos de propiedad

Para identificar los parámetros adecuados del modelo SARIMA utilizando las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF), se revisó el correlograma de la primera diferencia, observándose que en la parte no estacional los retardos significativos fueron 3 rezagos, por lo que se concluye que $q=3$, mientras que en la parte estacional se obtuvieron 3 rezagos estacionales significativos en la autocorrelación estacional, concluyendo que $Q=3$. En la PACF, se observó que para la parte

no estacional los retardos fueron 3 rezagos significativos, concluyendo que $p=3$, mientras que en la parte estacional se obtuvieron 2 rezagos estacionales en la autocorrelación parcial estacional, concluyendo que $P=2$. La selección del modelo se realizó mediante los criterios de información AIC y BIC, probando diferentes combinaciones de p , d , q , P , D y Q , y seleccionando el modelo con los valores más bajos de estos indicadores. Los resultados muestran que el modelo SARIMA con los valores AIC y BIC más bajos es aquel que posee los siguientes parámetros: $p=3$, $d=1$, $q=3$, $P=2$, $D=1$ y $Q=3$, presentando un AIC de 635.4 y un BIC de 660.33, lo cual indica que es el más adecuado para ajustar los datos con la mínima complejidad. El AIC de 635.4 muestra que el modelo logra un equilibrio óptimo entre ajuste y simplicidad en comparación con otros modelos evaluados, mientras que el BIC de 660.33 aplica una penalización mayor por el número de parámetros utilizados, indicando que este modelo es preferible porque no solo ajusta bien los datos, sino que también es relativamente simple.

Tabla 10. Parámetros óptimos SARIMA por criterio de selección

SARIMA							
Criterio de Selección	$p=0$	$p=1$	$p=1$	$p=3$	$p=2$	$p=2$	$p=3$
	$d=1$	$d=1$	$d=1$	$d=1$	$d=1$	$d=1$	$d=1$
	$q=3$	$q=3$	$q=3$	$q=3$	$q=3$	$q=3$	$q=3$
	$P=3$	$P=2$	$P=3$	$P=1$	$P=1$	$P=3$	$P=2$

SARIMA							
Criterio de Selección	D= 1	D= 1	D= 1	D= 1	D= 1	D= 1	D= 1
	Q= 3	Q= 3	Q= 3	Q= 3	Q= 3	Q= 3	Q= 3
AIC	640.19	641.73	638.71	638.35	639.29	643.86	635.4
BIC	660.97	662.51	661.57	661.21	660.06	668.79	660.33

Nota: Amaya Paiva & Farfan Morales (2025).

La comparación de los modelos SARIMA con diferentes parámetros revela que el modelo SARIMA (3,1,3)(2,1,3)[4] presenta el mejor desempeño con un MAE de 25.76, un MSE de 1128.66, un MAPE de 21.06% y un R² de 0.836, superando a las configuraciones SARIMA (1,1,3)(2,1,3)[4] y SARIMA (0,1,3)(3,1,3)[4] en todas las métricas evaluadas. Los coeficientes del modelo SARIMA (3,1,3)(2,1,3)[4] muestran valores significativos para cada retardo, con desviaciones estándar que respaldan la estabilidad de las estimaciones y la confiabilidad del modelo para generar pronósticos precisos de la entrega de títulos de propiedad en la provincia de Piura. Los coeficientes autorregresivos no estacionales incluyen -0.1918 para el retardo 1, 0.1108 para el retardo 2 y 0.6066 para el retardo 3, mientras que los coeficientes de media móvil no estacionales incluyen 0.1343 para el retardo 1, -0.1343 para el retardo 2 y -1.0000 para el retardo 3. Los coeficientes autorregresivos estacionales incluyen 0.5923 para el retardo 1 y 0.3833 para el retardo 2, mientras que los coeficientes de media móvil estacionales incluyen -1.9994 para

el retardo 1, 1.0645 para el retardo 2 y -0.0329 para el retardo 3. El modelo SARIMA demuestra un ajuste superior al ARIMA, como lo evidencian sus métricas de error significativamente menores y su mayor R^2 , lo que indica que la incorporación de componentes estacionales permite capturar patrones periódicos que el modelo ARIMA no lograba identificar adecuadamente, consolidando al modelo SARIMA como la herramienta más precisa y confiable para el pronóstico de la entrega de títulos de propiedad en la provincia de Piura.

Tabla 11. Comparación de Modelos SARIMA con Diferentes Parámetros

SARIMA			
Métricas	$p = 3$	$p = 1$	$p = 0$
	$d = 1$	$d = 1$	$d = 1$
	$q = 3$	$q = 3$	$q = 3$
	$P = 2$	$P = 2$	$P = 3$
	$D = 1$	$D = 1$	$D = 1$
	$Q = 3$	$Q = 3$	$Q = 3$
MAE	25.76	26.33	30.36
MSE	1128.66	1267.86	1818.63
MAPE	21.06%	21.81%	25.9%
R2 Core	0.836	0.816	0.736

Nota: Amaya Paiva & Farfan Morales (2025).

Tabla 12. Coeficientes del Modelo SARIMA

		Coeficiente	SE
AR	Retardo 1	-0.1918	0.149
	Retardo 2	0.1108	0.1418
	Retardo 3	0.6066	0.1258
Diferencia		1	
MA	Retardo 1	0.1343	0.0648
	Retardo 2	-0.1343	0.0607
	Retardo 3	-1	0.0768
AR, estacional	Retardo 1	0.5923	0.3897
	Retardo 2	0.3833	0.3328
Diferencia estacional		1	
MA, estacional	Retardo 1	-1.9994	0.69
	Retardo 2	1.0645	1.0456
	Retardo 3	-0.0329	0.4724

Nota: Amaya Paiva & Farfan Morales (2025).

El modelo puede expresarse matemáticamente como:

$$(1 + 0.5923L^5 + 0.3833L^{25})(1 - 0.1918L + 0.1108L^2 + 0.6066L^3)(1 - L)(1 - L^5)Y_t = (1 - 1.9994L^5 + 1.0645L^{25} - 0.0329L^{25})(1 + 0.1343L - 0.1343L^2 - L^3)et$$

Donde:

L es el operador de rezago. Componente AR (Autorregresivo):

$\phi_1 = -0.1918$: Indica el efecto de la dependencia lineal entre la observación actual y su valor inmediatamente anterior.

$\phi_2 = 0.1108$: Representa la dependencia lineal con la segunda observación anterior.

$\phi_3 = 0.6066$: Indica la dependencia lineal con la segunda observación anterior.

Componente I (Integrado):

$d = 1$: Una diferencia para eliminar tendencias de largo plazo.

Componente MA (Media Móvil):

$\phi_1 = 0.1343$: Describe el efecto de la media móvil en el error actual y su relación con los errores pasados.

$\phi_2 = -0.1343$: Indica la relación con el segundo término de la media móvil.

$\phi_3 = 1$: Describe la relación con el tercer término de la media móvil.

Componente AR Estacional:

$\phi_1 = 0.5923$: Indica el efecto de la dependencia lineal entre la observación actual y su valor al intervalo estacional anterior.

$\phi_2 = 0.3833$: Representa la dependencia lineal con el segundo intervalo estacional anterior.

Componente I Estacional

$D=1$: Una diferencia para eliminar las tendencias estacionales, haciéndolas estacionarias.

Componente MA Estacional:

$\phi_1 = -1.9994$: Describe el efecto de la media móvil en el error actual y su relación con el error pasado al intervalo estacional anterior.

$\phi_2 = 1.0645$: Indica la relación con el segundo error pasado al intervalo estacional anterior.

$\phi_3 = 0.0329$: Describe la relación con el tercer error pasado al intervalo estacional anterior.

Evaluación y validación del modelo SARIMA para el pronóstico de títulos de propiedad en Piura

Validación del modelo SARIMA y verificación de supuestos de normalidad

Una vez identificados los parámetros óptimos del modelo SARIMA, se llevó a cabo un exhaustivo proceso de validación para confirmar los supuestos del modelo de pronósticos de los títulos de propiedad entregados en la provincia de Piura durante el período 2008-2023, paso fundamental para garantizar que el modelo sea fiable y preciso antes de su implementación en la toma de deci-


siones. Este proceso de validación constituye una etapa crítica en la metodología de pronóstico, ya que permite establecer la credibilidad del modelo y su capacidad para generar predicciones que reflejen adecuadamente el comportamiento futuro de la variable en estudio. La literatura especializada ha enfatizado que la validación de modelos de series temporales no debe limitarse a la verificación de métricas de error, sino que debe incluir un examen riguroso de los supuestos subyacentes que garantizan la validez de las inferencias estadísticas (Box et al., 2015; Hyndman & Athanasopoulos, 2021). En este sentido, el proceso de validación del modelo SARIMA (3,1,3)(2,1,3)[4] comprendió múltiples dimensiones de análisis, incluyendo la comparación entre valores observados y ajustados, la evaluación de la normalidad de los residuos, la verificación de la homocedasticidad, el examen de la independencia de los errores, la comprobación de la ausencia de autocorrelación y la confirmación de que el modelo captura adecuadamente la estacionalidad de los datos. Cada una de estas dimensiones aporta información valiosa sobre el desempeño del modelo y su capacidad para generar pronósticos confiables, por lo que su verificación sistemática constituye una práctica recomendada en la literatura metodológica (Makridakis et al., 2020; Petropoulos et al., 2022).

La Figura 8 presenta los valores ajustados del modelo SARIMA (3,1,3)(2,1,3)[4] para los títulos de propiedad

entregados en la provincia de Piura entre 2008 y 2023, revelando una notable concordancia entre los valores reales, representados por la línea azul punteada, y las predicciones ajustadas del modelo, mostradas con la línea roja continua. Esta alineación precisa entre los datos observados y los valores estimados por el modelo constituye un indicador visual de la capacidad del SARIMA para capturar la dinámica subyacente de la serie temporal, incluyendo tanto las tendencias de largo plazo como las fluctuaciones estacionales y los movimientos irregulares que caracterizan a los datos históricos. La proximidad entre ambas líneas a lo largo de todo el período analizado sugiere que el modelo ha logrado identificar y replicar los patrones fundamentales que gobiernan el comportamiento de la entrega de títulos de propiedad, lo que resulta esencial para garantizar la fiabilidad de los pronósticos futuros (Makridakis et al., 2020; Petropoulos et al., 2022). Este hallazgo es particularmente relevante en el contexto de la gestión pública, donde la capacidad de anticipar la demanda de servicios administrativos como la titulación de propiedades permite a las autoridades municipales planificar con anticipación la asignación de recursos humanos, financieros y materiales, optimizando así la eficiencia operativa y mejorando la calidad de los servicios ofrecidos a la ciudadanía (Chatfield, 2019; Wei, 2018). La validación del modelo a través de métricas como MSE, MAPE y MAE confirma su precisión y robustez, consolidándolo como una

herramienta esencial para la toma de decisiones en políticas de vivienda y desarrollo urbano, ya que la precisión en la predicción es fundamental para anticipar la demanda de titulación y optimizar los procesos administrativos (Hyndman & Koehler, 2006; Chai & Draxler, 2014). La experiencia acumulada en aplicaciones de modelos SARIMA en contextos de gestión pública ha demostrado que la capacidad de un modelo para ajustarse adecuadamente a los datos históricos es un predictor clave de su desempeño futuro, por lo que la alineación observada en la Figura 12 constituye un indicador sólido de la calidad predictiva del modelo SARIMA (Gardner, 2019; Taylor, 2020).

Figura 8. Valores ajustados del SARIMA(3,1,3)(2,1,3)[4] para títulos en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Para evaluar la validez del modelo SARIMA, resulta crucial verificar que los residuos, es decir, las diferencias

entre los valores observados y los valores estimados sigan una distribución normal, garantizando que el modelo ha capturado correctamente las dependencias en los datos y que los errores restantes son aleatorios y no estructurados. La normalidad de los residuos es un supuesto fundamental en la modelización estadística, ya que su incumplimiento puede afectar la validez de las pruebas de hipótesis y la precisión de los intervalos de confianza construidos a partir de los pronósticos (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). La prueba de Shapiro-Wilk aplicada a los residuos del modelo SARIMA arrojó un valor de significancia que permite evaluar el cumplimiento de este supuesto, cuyos resultados se presentan en la Tabla 18. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de normalidad, permitiendo inferir que los residuos pueden considerarse provenientes de una distribución normal, sugiriendo que el modelo de pronóstico SARIMA es adecuado para los datos analizados (Fernández y Díaz, 2002; Hernández et al., 2014). Este resultado es particularmente significativo porque la normalidad de los residuos implica que los errores del modelo se distribuyen aleatoriamente alrededor de cero, sin presentar sesgos sistemáticos que pudieran indicar una especificación inadecuada del modelo. La confirmación de este supuesto es especialmente relevante en el contexto de la

gestión pública, donde la validez de las inferencias estadísticas basadas en los pronósticos es fundamental para la toma de decisiones informadas y la asignación eficiente de recursos (Armstrong, 2020; Fildes & Goodwin, 2021).

Tabla 13. Normalidad de residuos del modelo SARIMA


Prueba de Shapiro-Wilk	
Estadístico	0.976
gl	64
Sig.	0.241

Nota: Amaya Paiva & Farfan Morales (2025).

La Figura 9, correspondiente al gráfico Q-Q de los residuos, muestra que los puntos se encuentran próximos a la línea diagonal, reforzando visualmente la conclusión de que los residuos pueden ser tratados como normalmente distribuidos en los análisis posteriores. La confirmación de la normalidad de los residuos valida la fiabilidad del modelo SARIMA (3,1,3)(2,1,3)[4] para realizar pronósticos precisos, ya que el cumplimiento de este supuesto garantiza que las inferencias estadísticas basadas en el modelo sean confiables y que los intervalos de confianza construidos a partir de los pronósticos tengan la cobertura esperada (Box et al., 2015; Wei, 2018). Este resultado resulta particularmente relevante porque la normalidad de los residuos es un indicador de que el modelo ha capturado adecuadamente la estructura sistemática de los datos, dejando únicamente fluctuaciones aleatorias que

no presentan patrones discernibles, lo que constituye una condición necesaria para la validez de cualquier modelo de pronóstico (Ljung & Box, 2018; McLeod et al., 2019). La experiencia acumulada en aplicaciones de modelos SARIMA en contextos de gestión pública ha demostrado que la verificación de la normalidad de los residuos es un paso crítico que no debe omitirse, ya que su incumplimiento puede conducir a estimaciones sesgadas y pronósticos poco confiables, comprometiendo así la calidad de las decisiones basadas en estos pronósticos (Armstrong, 2020; Fildes & Goodwin, 2021). El gráfico Q-Q proporciona una evidencia visual complementaria que refuerza la conclusión obtenida mediante la prueba estadística, ofreciendo una confirmación adicional de que los residuos cumplen con el supuesto de normalidad (Brockwell & Davis, 2016; Shumway & Stoffer, 2017).

Figura 9. Gráfico Q-Q de residuos del SARIMA para títulos en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

Comparación de modelos y selección del enfoque predictivo óptimo

Tras un análisis minucioso de los modelos de Holt-Winters y la metodología de Box-Jenkins, se presenta una tabla que detalla los parámetros óptimos y sus respectivas métricas de rendimiento, esencial para identificar el modelo que ofrece la mayor precisión en el pronóstico de la entrega de títulos de propiedad en la provincia de Piura durante el periodo 2024-2025. La comparación de modelos constituye una etapa fundamental en el proceso de selección del enfoque predictivo más adecuado, ya que permite evaluar de manera objetiva las fortalezas y debilidades de cada metodología en relación con las características específicas de los datos en estudio (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020). La Tabla 19 muestra la comparación de los modelos evaluados, revelando que el modelo SARIMA ha demostrado ser el más efectivo entre los analizados, presentando las mejores métricas de rendimiento con un Error Absoluto Medio (MAE) de 25.76, un Error Cuadrático Medio (MSE) de 1128.66, un Error Porcentual Absoluto Medio (MAPE) de 21.06%, y un coeficiente de determinación (R^2) de 0.836. Estos indicadores sugieren que el modelo SARIMA no solo es el más preciso, sino también el más confiable para pronosticar la entrega de títulos de propiedad en la provincia de Piura durante el periodo 2024-2025, superando

significativamente a los modelos Aditivo de Holt-Winters (MAE=34.678, MSE=2121.32, MAPE=26.86%, $R^2=0.692$), Multiplicativo de Holt-Winters (MAE=38.05, MSE=2424.01, MAPE=34.03%, $R^2=0.648$) y ARIMA (MAE=38.44, MSE=2558.44, MAPE=33.29%, $R^2=0.63$). La superioridad del modelo SARIMA en estas métricas implica una mayor exactitud en la predicción de los resultados, lo cual es vital para una planificación efectiva y la toma de decisiones en el ámbito de políticas de vivienda y desarrollo urbano, donde la capacidad de anticipar la demanda de titulación permite una asignación más eficiente de los recursos y una mejor organización de los procesos administrativos (Gardner, 2019; Taylor, 2020).

Tabla 14. Comparación Holt-Winters vs Box-Jenkins para pronóstico de títulos en Piura

Modelo	Parámetros	MAE	MSE	MAPE	R^2_{core}
Aditivo de Holt-Winters	$(\alpha)=0.958701$ $(\gamma)=0.000248$ $(S)=0.034085$	34.678	2121.32	26.86%	0.692
Multiplicativo de Holt-Winters	$(\alpha)=0.774$ $(\gamma)=0.0129$ $(S)=0.0428$	38.05	2424.01	34.03%	0.648
ARIMA	$p=3$ $d=1$ $q=3$	38.44	2558.44	33.29%	0.63
SARIMA	$p=3$ $d=1$ $q=3$ $P=2$ $D=1$ $Q=3$	25.76	1128.66	21.06%	0.836

Nota: Amaya Paiva & Farfan Morales (2025).

La capacidad del modelo SARIMA para explicar una alta proporción de la variabilidad observada, como indica su elevado coeficiente R^2 de 0.836, refuerza su idoneidad para este tipo de pronósticos, asegurando que las autoridades puedan contar con proyecciones más precisas y así desarrollar estrategias mejor informadas para atender las necesidades de la población (Hyndman & Koehler, 2006; Chai & Draxler, 2014). El R^2 , que mide la proporción de la varianza de la variable dependiente que es explicada por el modelo, alcanza un valor de 0.836 en el caso del modelo SARIMA, lo que indica que aproximadamente el 83.6% de la variabilidad en la entrega de títulos de propiedad puede ser explicada por el modelo, dejando solo un 16.4% atribuible a factores aleatorios no modelados. Este nivel de ajuste es considerablemente alto para una serie temporal con las características de la aquí analizada, donde múltiples factores administrativos, políticos y sociales pueden influir en el comportamiento de la variable (Willmott & Matsuura, 2019; Petropoulos et al., 2022). La implementación del modelo SARIMA como herramienta principal de pronóstico permitirá optimizar los procesos de entrega de títulos de propiedad, brindando un marco sólido y fiable para la planificación y ejecución de políticas públicas en Piura, lo que contribuye directamente a una mejor organización y optimización de los procesos administrativos, facilitando una respuesta proactiva a las demandas de la población. La elección del modelo SARIMA se fun-

damenta no solo en sus métricas de error superiores, sino también en su capacidad para capturar adecuadamente la estructura temporal de los datos, incluyendo tanto las tendencias de largo plazo como las fluctuaciones estacionales que caracterizan a la serie de títulos de propiedad (Willmott & Matsuura, 2019; Petropoulos et al., 2022). La literatura especializada ha documentado que los modelos SARIMA son particularmente adecuados para series temporales con patrones estacionales bien definidos, como es el caso de la entrega de títulos de propiedad, que presenta variaciones sistemáticas asociadas a ciclos administrativos y presupuestales (Makridakis et al., 2020; Chatfield, 2019). Esta característica convierte al modelo SARIMA en una opción metodológica especialmente apropiada para el contexto de la gestión pública, donde la capacidad de anticipar fluctuaciones estacionales resulta fundamental para la planificación efectiva y la asignación eficiente de recursos (Armstrong, 2020; Fildes & Goodwin, 2021). La superioridad del modelo SARIMA sobre el modelo ARIMA tradicional se debe precisamente a su capacidad para incorporar componentes estacionales que capturan las fluctuaciones periódicas que caracterizan a la serie, lo que se traduce en una mejora significativa en la precisión de los pronósticos (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). Además, el modelo SARIMA supera a los modelos de Holt-Winters en todas las métricas evaluadas, lo que sugiere que la metodología de Box-Jenkins, con su enfoque sistemático para la identificación, estimación y


verificación de modelos, ofrece ventajas significativas en términos de precisión y confiabilidad para este tipo de series temporales (Box et al., 2015; Wei, 2018). La comparación de modelos también revela que el modelo aditivo de Holt-Winters supera al multiplicativo y al ARIMA en términos de precisión, lo que sugiere que para esta serie temporal en particular, el enfoque aditivo para el tratamiento de la estacionalidad es más apropiado que el multiplicativo, y que la incorporación de componentes estacionales en el modelo ARIMA produce una mejora sustancial en el desempeño predictivo.

Verificación exhaustiva de los supuestos del modelo SARIMA

Tras la elección del modelo SARIMA $(3,1,3)(2,1,3)$ [4], resulta fundamental realizar una revisión exhaustiva de los supuestos del error para confirmar que la selección es la adecuada, verificando seis supuestos fundamentales: Normalidad, Media Cero, Homocedasticidad, Independencia, No Autocorrelación y Estacionalidad. Estos supuestos constituyen el conjunto de condiciones que deben cumplirse para que las inferencias estadísticas basadas en el modelo sean válidas y los pronósticos generados sean confiables (Box et al., 2015; Hyndman & Athanasopoulos, 2021). La verificación de estos supuestos no es un mero requisito metodológico, sino una garantía de que el mo-

delo ha capturado adecuadamente la estructura de los datos y que los errores residuales no contienen información sistemática que pudiera ser modelada para mejorar el desempeño predictivo (Wei, 2018; Chatfield, 2019). La Figura 14 presenta los residuos de los pronósticos del modelo SARIMA, permitiendo una inspección visual inicial de su comportamiento, donde se observa que los residuos se distribuyen de manera aleatoria alrededor de cero, sin presentar patrones sistemáticos que pudieran indicar una especificación inadecuada del modelo. Esta inspección visual constituye un primer paso importante en el proceso de validación, ya que permite identificar de manera rápida posibles problemas en el modelo que podrían requerir un análisis más detallado mediante pruebas estadísticas formales (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020). La aleatoriedad de los residuos alrededor de cero es un indicador positivo de que el modelo ha capturado adecuadamente la estructura sistemática de los datos, dejando únicamente fluctuaciones aleatorias que no presentan patrones discernibles (Chatfield, 2019; Wei, 2018).

Figura 10. Residuos del SARIMA(3,1,3)(2,1,3)[4] para títulos en Piura, 2008-2023



Nota: Amaya Paiva & Farfan Morales (2025).

La prueba de Shapiro-Wilk aplicada a los residuos arrojó un valor de significancia que permite evaluar el cumplimiento del supuesto de normalidad, cuyos resultados se presentan en la Tabla 20. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de normalidad, confirmando que los residuos pueden considerarse provenientes de una distribución normal. Este resultado es consistente con el gráfico Q-Q presentado anteriormente, que mostraba una proximidad de los puntos a la línea diagonal, reforzando la conclusión de que los residuos cumplen con el supuesto de normalidad. La confirmación de este supuesto es fundamental porque garantiza que las pruebas estadísticas basadas en la distribución normal sean válidas y que los intervalos de con-

fianza contruidos a partir de los pronósticos tengan la cobertura esperada (Box et al., 2015; Ljung & Box, 2018). La literatura especializada ha documentado que el incumplimiento del supuesto de normalidad puede afectar la precisión de los intervalos de confianza y la validez de las pruebas de hipótesis, por lo que su verificación constituye un paso crítico en el proceso de validación del modelo (Brockwell & Davis, 2016; Shumway & Stoffer, 2017).

Tabla 15. Evaluación de Normalidad de los Residuos del Modelo SARIMA

Prueba de Shapiro-Wilk	
Estadístico	0.976
gl	64
Sig.	0.241

Nota: Amaya Paiva & Farfan Morales (2025).

La prueba T de Student para la media de los residuos mostró un valor de significancia que permite evaluar el cumplimiento del supuesto de media cero, cuyos resultados se presentan en la Tabla 21. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de que los residuos presentan media cero, concluyendo que los residuos tienen una media que es estadísticamente igual a cero. Este resultado es fundamental porque garantiza que el modelo no presenta sesgos sistemáticos en sus predic-

ciones, es decir, que en promedio el modelo no tiende a sobreestimar ni subestimar los valores de la serie (Ljung & Box, 2018; McLeod et al., 2019). El cumplimiento del supuesto de media cero es particularmente importante en el contexto de la gestión pública, donde los sesgos sistemáticos en los pronósticos podrían conducir a una planificación inadecuada y a una asignación ineficiente de recursos (Armstrong, 2020; Fildes & Goodwin, 2021). La verificación de este supuesto mediante la prueba T de Student proporciona una evidencia estadística sólida de que el modelo no presenta sesgos significativos, lo que aumenta la confianza en la precisión de los pronósticos generados (Hyndman & Athanasopoulos, 2021; Wei, 2018).

Tabla 16. Prueba t de Student para media de residuos del SARIMA

Prueba T de Student	
Estadístico	-0.361
Sig.	0.719

Nota: Amaya Paiva & Farfan Morales (2025).

La prueba de Breusch-Pagan para evaluar la homocedasticidad arrojó un valor de significancia que permite evaluar el cumplimiento de este supuesto, cuyos resultados se presentan en la Tabla 22. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de

varianza constante, concluyendo que los residuos presentan homocedasticidad. La homocedasticidad, o varianza constante de los errores, es un supuesto importante porque garantiza que la precisión de las predicciones del modelo sea consistente a lo largo del tiempo, sin que existan períodos en los que los errores sean sistemáticamente mayores o menores (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). El cumplimiento de este supuesto es particularmente relevante en el contexto de la gestión pública, donde la consistencia en la precisión de los pronósticos permite una planificación más confiable y una asignación de recursos más eficiente (Armstrong, 2020; Fildes & Goodwin, 2021). La verificación de la homocedasticidad mediante la prueba de Breusch-Pagan proporciona una evidencia estadística sólida de que la varianza de los errores se mantiene constante a lo largo del tiempo, lo que aumenta la confianza en la fiabilidad de los pronósticos generados (Hyndman & Athanasopoulos, 2021; Wei, 2018).

Tabla 17. Prueba de homocedasticidad para residuos del SARIMA

Prueba de Breusch-Pagan	
Estadístico	0.651
Sig.	0.42

Nota: Amaya Paiva & Farfan Morales (2025).

La prueba de CUSUM para evaluar la independencia de los residuos mostró un valor de significancia que

permite evaluar el cumplimiento de este supuesto, cuyos resultados se presentan en la Tabla 18. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de independencia, confirmando que no hay cambios estructurales en los errores. La independencia de los errores es un supuesto crítico porque garantiza que los residuos no estén correlacionados entre sí, lo que podría indicar que el modelo no ha capturado adecuadamente la estructura de dependencia temporal de los datos (Hyndman & Athanasopoulos, 2021; Wei, 2018). El cumplimiento de este supuesto es fundamental porque la presencia de dependencia en los residuos podría indicar que el modelo no ha capturado adecuadamente la estructura temporal de los datos, lo que comprometería la validez de los pronósticos generados (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). La verificación de la independencia mediante la prueba de CUSUM proporciona una evidencia estadística sólida de que los errores son independientes entre sí, lo que aumenta la confianza en la validez del modelo y en la precisión de los pronósticos generados (Ljung & Box, 2018; McLeod et al., 2019).

Tabla 18. Prueba de Independencia para los Residuos del Modelo SARIMA

Prueba de CUSUM	
Estadístico	0.865
Sig.	0.442

Nota: Amaya Paiva & Farfan Morales (2025).

La prueba de Ljung-Box para evaluar la no autocorrelación de los residuos arrojó un valor de significancia que permite evaluar el cumplimiento de este supuesto, cuyos resultados se presentan en la Tabla 24. El análisis de esta tabla revela que el valor de significancia obtenido es superior al nivel teórico de 0.05, lo que indica que no se encontró evidencia suficiente para rechazar la hipótesis nula de no autocorrelación, concluyendo que no existe autocorrelación en los residuos para el retardo 1. La ausencia de autocorrelación en los residuos es fundamental porque garantiza que el modelo ha capturado adecuadamente las dependencias temporales en los datos, dejando únicamente fluctuaciones aleatorias que no presentan patrones sistemáticos (Ljung & Box, 2018; McLeod et al., 2019). El cumplimiento de este supuesto es particularmente importante porque la presencia de autocorrelación en los residuos indicaría que el modelo no ha capturado adecuadamente la estructura temporal de los datos, lo que comprometería la validez de los pronósticos generados (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). La

verificación de la no autocorrelación mediante la prueba de Ljung-Box proporciona una evidencia estadística sólida de que los residuos no presentan autocorrelación significativa, lo que aumenta la confianza en la validez del modelo y en la precisión de los pronósticos generados (Hyndman & Athanasopoulos, 2021; Wei, 2018).

Tabla 19. Prueba de no autocorrelación para residuos del SARIMA


Prueba de Ljung-Box	
Estadístico	0.013
Sig.	0.909

Nota: Amaya Paiva & Farfan Morales (2025).

Finalmente, para verificar la estacionalidad en los residuos, se construyó un correlograma estacional que permite visualizar la autocorrelación estacional en los residuos, el cual se presenta en la Figura 11. En esta figura se observa que las barras se encuentran dentro del intervalo de confianza, indicando que no hay autocorrelaciones significativas en los residuos, lo que sugiere que el modelo SARIMA ha capturado adecuadamente la estacionalidad de los datos. Este resultado es particularmente relevante porque confirma que el componente estacional del modelo ha logrado capturar las fluctuaciones periódicas que caracterizan a la serie, sin dejar patrones estacionales residuales que pudieran indicar una especificación inadecuada del componente estacional (Box et al.,

2015; Hyndman & Athanasopoulos, 2021). La verificación de la estacionalidad mediante el correlograma estacional proporciona una evidencia visual sólida de que el modelo ha capturado adecuadamente los patrones estacionales de los datos, lo que aumenta la confianza en la capacidad del modelo para generar pronósticos precisos que reflejen adecuadamente las fluctuaciones periódicas de la serie (Chatfield, 2019; Wei, 2018). El cumplimiento de este supuesto es fundamental porque garantiza que el componente estacional del modelo no deje patrones residuales que pudieran ser modelados para mejorar el desempeño predictivo (Makridakis et al., 2020; Petropoulos et al., 2022).

Figura 11. Correlograma Estacional de los Residuos del Modelo SARIMA



Nota: Amaya Paiva & Farfan Morales (2025).

Al finalizar la exhaustiva revisión de los seis supuestos para los residuos del modelo SARIMA $(3,1,3)(2,1,3)$

[4], se concluye que todos los supuestos fueron cumplidos de manera significativa, lo que implica que el modelo ha sido validado correctamente en cuanto a normalidad, media cero, homocedasticidad, independencia, no autocorrelación y estacionalidad. La confirmación de estos supuestos resulta esencial para garantizar que el modelo SARIMA funcione de manera óptima y fiable, permitiendo generar pronósticos precisos y eficientes para los ocho trimestres siguientes al cuarto trimestre de 2023. Gracias a la robustez del modelo y la validación de sus supuestos, las predicciones obtenidas serán de alta calidad, facilitando la planificación y toma de decisiones informadas, lo que constituye un avance significativo en la capacidad de la municipalidad para anticipar la demanda de titulación y optimizar sus procesos administrativos (Brockwell & Davis, 2016; Shumway & Stoffer, 2017). La literatura especializada ha enfatizado que la verificación de los supuestos del modelo es un paso crítico que no debe ser omitido, ya que su incumplimiento puede comprometer seriamente la validez de las inferencias y la confiabilidad de los pronósticos generados (Hyndman & Athanasopoulos, 2021; Wei, 2018).

Generación de pronósticos trimestrales y su utilidad para la planificación estratégica

Mediante la implementación del modelo SARIMA $(3,1,3)(2,1,3)[4]$, se generaron pronósticos detallados y precisos sobre los títulos de propiedad que serán entregados por la municipalidad durante los ocho trimestres consecutivos al cuarto trimestre de 2023. La Tabla 25 presenta estos pronósticos, acompañados de sus correspondientes límites de confianza al 80% y 95%, proporcionando no solo una medida clara de la fiabilidad y variabilidad de las proyecciones, sino también información fundamental para la planificación estratégica y la toma de decisiones informadas por parte de las autoridades municipales. Los intervalos de confianza son particularmente importantes porque proporcionan una medida de la incertidumbre asociada con cada pronóstico, permitiendo a los tomadores de decisiones evaluar el riesgo asociado con diferentes escenarios y desarrollar planes de contingencia apropiados (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020). Se destaca que, en el primer trimestre de 2024, se pronostica la entrega de aproximadamente 297.8 títulos de propiedad, con un intervalo de confianza del 80% entre 243.809 y 351.791, y del 95% entre 215.227 y 380.373. Este pronóstico inicial sugiere un nivel de actividad relativamente alto en la entrega de títulos al inicio del período proyectado, lo que podría estar asociado a la

implementación de políticas de formalización impulsadas por las autoridades municipales o a una mayor demanda de regularización por parte de la población (Chatfield, 2019; Wei, 2018). A medida que avanzamos en los trimestres, los pronósticos muestran una tendencia de variación, con picos en ciertos trimestres y disminuciones en otros, revelando fluctuaciones estacionales en los trimestres proyectados, lo cual es típico en series temporales con componentes estacionales.

Tabla 20. Pronósticos trimestrales de títulos en Piura, 2024-2025

Año	Trimestre	Pronóstico	80%		95%	
			Límite Inferior	Límite Superior	Límite Inferior	Límite Superior
2024	Q1	297.8	243.809	351.791	215.227	380.373
2024	Q2	336.812	263.571	410.054	224.799	448.825
2024	Q3	140.067	52.446	227.689	6.062	274.073
2024	Q4	253.871	162.093	345.650	113.508	394.234
2025	Q1	285.137	192.484	377.790	143.437	426.838
2025	Q2	318.895	225.519	412.271	176.088	461.701
2025	Q3	160.229	66.966	253.492	17.595	302.862
2025	Q4	294.662	201.142	388.181	151.636	437.688


Nota: Amaya Paiva & Farfan Morales (2025).

La Figura 16, junto con la Tabla 19, presenta los pronósticos de la entrega de títulos de propiedad en la provincia de Piura para los trimestres de los años 2024 y 2025, generados mediante el modelo SARIMA (3,1,3)(2,1,3)[4], mostrando que los pronósticos generados por el mode-

lo SARIMA exhiben una buena capacidad para capturar las tendencias y estacionalidades presentes en los datos históricos, mientras que los intervalos de confianza proporcionan una medida clara de la variabilidad y fiabilidad de las proyecciones. La representación gráfica de los pronósticos, con las áreas sombreadas que indican los intervalos de confianza, permite una comprensión visual de la incertidumbre asociada con cada proyección, facilitando la identificación de los períodos donde la incertidumbre es mayor y donde, por lo tanto, se requiere una planificación más flexible (Armstrong, 2020; Chatfield, 2019). La Figura 17 proporciona una representación integral del comportamiento histórico, los valores ajustados, los pronósticos y los límites de confianza del modelo SARIMA para la entrega de títulos de propiedad en Piura durante el periodo 2024-2025, ofreciendo una visión completa de cómo el modelo se ajusta a los datos históricos y genera pronósticos precisos para el futuro. Esta representación integrada es particularmente valiosa porque permite visualizar la continuidad entre el comportamiento histórico y las proyecciones futuras, así como la magnitud de la incertidumbre que acompaña a cada pronóstico (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020). La línea de pronósticos muestra cómo se espera que varíen las entregas trimestrales de títulos de propiedad, capturando tanto las tendencias generales como las fluctuaciones estacionales, mientras que los límites de confianza son


esenciales porque proporcionan una medida de la incertidumbre asociada con las proyecciones y permiten a las autoridades de la municipalidad de Piura planificar estratégicamente y tomar decisiones informadas con un alto grado de fiabilidad.

Figura 12. Pronósticos trimestrales de títulos en Piura, 2024-2025



Nota: Amaya Paiva & Farfan Morales (2025).

Figura 13. Comportamiento, ajuste, pronósticos y límites del SARIMA para títulos en Piura, 2024-2025



Nota: Amaya Paiva & Farfan Morales (2025).

Discusión de resultados en el contexto de investigaciones previas

Tras la obtención de los resultados alineados con los objetivos e hipótesis formulados, se realizó un análisis crítico en contraste con hallazgos de investigaciones previas, evaluando el desarrollo integral del presente estudio frente a otros trabajos previos. Este ejercicio de contrastación es fundamental porque permite situar los resultados obtenidos en el contexto más amplio de la literatura especializada, identificando convergencias y divergencias que enriquecen la interpretación de los hallazgos y contribuyen al avance del conocimiento en el campo de los pronósticos de series temporales aplicados a la gestión pública (Hyndman & Athanasopoulos, 2021; Makridakis et al., 2020). El desarrollo de los objetivos específicos permitió analizar y modelar la serie temporal de la entrega de títulos de propiedad en la provincia de Piura entre 2008 y 2023, identificándose patrones de tendencia al alza, estacionalidad trimestral y fluctuaciones aleatorias en la serie, observándose que la serie original no era estacionaria, pero se logró estacionariedad aplicando la primera diferencia. Los resultados son consistentes con los hallazgos de Carranza (2019), quien utilizó la metodología Box-Jenkins seleccionando como modelo óptimo el SARIMA (1,1,0)(1,1,0), coincidiendo en el uso de SARI-MA para series temporales no estacionarias y estaciona-

les, aunque las diferencias en los contextos de aplicación (títulos de propiedad versus exportaciones de bienes) y en los parámetros del modelo se explican por las características intrínsecas de cada serie. Carranza (2019), identificó que el modelo seleccionado no subestimó ni sobreestimó las predicciones, lo que refuerza la capacidad de los modelos SARIMA para capturar patrones estacionales y tendencias en series temporales, hallazgo que se alinea con los resultados del presente estudio donde el modelo SARIMA demostró un desempeño superior en términos de precisión y ajuste.

Asimismo, Ruiz (2024), empleó el modelo SARI-MA para pronósticos energéticos, obteniendo un MSE de 4.738, demostrando que el modelo SARIMA es una herramienta eficaz para analizar series de tiempo con estacionalidad, coincidiendo con la elección del modelo SARI-MA en el presente estudio, lo que refuerza su capacidad para capturar patrones estacionales y tendencias en series temporales, aunque las métricas de error no son directamente comparables debido a la naturaleza y escalas de las variables en cuestión. Roque (2022), quien empleó el modelo SARIMA para predecir la demanda de pasajeros en clústeres de estaciones del Metropolitano, logró un rendimiento robusto con un RMSPE entre 6.37% y 8.13% y un R^2 entre 0.91 y 0.98, encontrando que el modelo SARIMA es eficaz para captar patrones estacionales y tendencias en series temporales, similitud que refuerza su aplicabi-

lidad en diversos contextos. En la misma línea, Arechaga y Bayona (2022) pronosticaron la producción de arroz en cáscara en Perú utilizando SARIMA, encontrando que SARIMA (0,0,2)(0,1,2) con un R^2 de 0.8952 era el más adecuado, evidenciando la capacidad de una aplicación exitosa de los modelos SARIMA en la producción agrícola y en la entrega de títulos de propiedad, lo que destaca su versatilidad.

Por otro lado, el estudio difiere respecto a Herrera et al. (2022), quienes demostraron que el modelo Holt-Winters multiplicativo fue el más adecuado para la producción de cereales en Perú, con un BIC de 5754.20 y un AIC de 5697.48, superior al ARIMA en precisión, mientras que en el presente estudio el modelo SARIMA mostró un mejor desempeño, lo que subraya que no siempre el modelo SARIMA va a ser el mejor frente a cualquier conjunto de datos, sino que el modelo debe trabajarse de acuerdo a los datos y el contexto estudiado. Mientras que Albán (2023), quien realizó un pronóstico de ingresos tributarios en Piura utilizando modelos ARIMA y Holt-Winters, concluyó que el modelo Winters, con un RMSE de 27.027, era más eficiente que el ARIMA, mientras que en el presente estudio el modelo SARIMA mostró un mejor desempeño en términos de error y ajuste, subrayando la importancia de seleccionar el modelo adecuado según las características específicas de la serie temporal. Abad (2020) modeló y pronosticó atenciones médicas en un hospital de Piura

utilizando ARIMA, destacando el modelo ARIMA (0,1,1) con un R^2 de 0.6415 y un RMSE de 79.36343, mientras que el modelo SARIMA en el presente estudio mostró un mejor desempeño en términos de R^2 y MAPE, destacando la efectividad de los modelos ARIMA y SARIMA para captar patrones y tendencias en series temporales. Mejía y Páez (2023), encontraron que el modelo SARIMAX fue el más efectivo para predecir la producción semanal de rosas, logrando un MAPE de 20.91% y un R^2 ajustado de 0.8118, superando a Holt-Winters y Gradient Boosting, destacando la versatilidad del modelo SARIMAX dentro de la familia Box-Jenkins por la incorporación de variables exógenas. Patrick et al. (2023), utilizó modelos de SARIMAX, Space State y LSTM para prever el rendimiento de la cosecha de banano en Tanzania, donde el modelo de conjunto alcanzó el R^2 más alto (0.9999), superando a los demás modelos, resaltando la robustez de los modelos de la familia Box-Jenkins en diversos contextos de aplicación.

Capítulo 5

Hallazgos fundamentales y proyecciones para la gestión de títulos de propiedad en Piura

LA PROPIEDAD EN CIFRAS:
pronósticos estadísticos para la formalización urbana en Piura

Síntesis de los resultados obtenidos en la modelización de la serie temporal

El análisis exhaustivo de la serie temporal correspondiente a los títulos de propiedad entregados en la provincia de Piura durante el período comprendido entre 2008 y 2023 permitió identificar patrones de comportamiento claramente diferenciados que resultan esenciales para comprender la dinámica del proceso de titulación en la región. La tendencia general de la serie evidenció un comportamiento ascendente a lo largo del tiempo, lo que sugiere una mejora progresiva en la gestión administrativa de la titulación o un incremento en la demanda de regularización por parte de la población, fenómeno que podría estar asociado a políticas gubernamentales más efectivas, a una mayor conciencia sobre la importancia de la formalización de la propiedad o a factores demográficos que han incrementado la presión sobre el mercado de suelo urbano en la provincia. Esta tendencia al alza se vio acompañada por fluctuaciones estacionales de carácter trimestral, que reflejan la existencia de ciclos periódicos en la entrega de títulos, posiblemente asociados a la disponibilidad presupuestal, a los calendarios administrativos, a la estacionalidad de la demanda de servicios de titulación o a factores institucionales que condicionan el ritmo de los procesos de formalización. La identificación de estos patrones resulta fundamental porque proporciona una

base empírica sólida para comprender el comportamiento pasado de la variable y para anticipar su evolución futura, lo que constituye el primer paso en la construcción de un sistema de pronóstico confiable y útil para la planificación institucional.

El análisis de estacionariedad reveló que la serie original no cumplía con esta condición fundamental para la aplicación de modelos predictivos, lo que requirió la aplicación de una diferenciación de primer orden para lograr la estacionariedad, confirmada mediante la prueba de Dickey-Fuller aumentada con un nivel de significancia de 0.037, que permitió rechazar la hipótesis de raíz unitaria y establecer las condiciones necesarias para la modelización. Este hallazgo es particularmente relevante porque la estacionariedad constituye un requisito indispensable para la aplicación de la metodología Box-Jenkins, que se fundamenta en el supuesto de que los procesos estocásticos que generan los datos son invariantes en el tiempo, lo que permite utilizar las propiedades de autocorrelación de la serie para identificar la estructura del modelo más adecuado. La transformación de la serie mediante diferenciación no solo garantiza el cumplimiento de los supuestos estadísticos, sino que también permite eliminar la influencia de la tendencia, facilitando la identificación de los patrones estacionales y la estimación precisa de los parámetros del modelo. La literatura especializada ha documentado que la diferenciación es una técnica ampliamente utilizada en el análisis de series temporales para

abordar la no estacionariedad, y su aplicación en el contexto de la entrega de títulos de propiedad ha demostrado ser efectiva para estabilizar la serie y prepararla para el modelado predictivo (Brockwell & Davis, 2016; Shumway & Stoffer, 2017).

En el ámbito de los modelos de suavizamiento exponencial, se determinó que el modelo de Holt-Winters aditivo, con parámetros Alpha ($\alpha = 0.9587$), Gamma ($\gamma = 0.0002$) y Delta ($\delta = 0.0341$), constituyó la opción más precisa entre las configuraciones evaluadas dentro de esta familia metodológica. Este modelo alcanzó un Error Porcentual Absoluto Medio (MAPE) de 26.86% y un coeficiente de determinación R^2 de 0.692, lo que indica que aproximadamente el 69.2% de la variabilidad en la entrega de títulos de propiedad puede ser explicada por el modelo, representando un nivel de ajuste moderado pero significativo para un fenómeno complejo influenciado por múltiples factores administrativos, políticos y sociales. La interpretación de estos parámetros de suavizamiento revela aspectos interesantes sobre la dinámica de la serie: el valor alto de Alpha (0.9587) sugiere que el nivel de la serie responde rápidamente a las observaciones más recientes, lo que indica que el proceso de titulación es sensible a cambios recientes en las condiciones institucionales o en la demanda de servicios. Por el contrario, el valor extremadamente bajo de Gamma (0.0002) indica que la tendencia de la serie es muy estable y cambia muy lentamente, lo que sugiere que los factores que determinan la

dirección general de la entrega de títulos son estructurales y no varían significativamente en el corto plazo. Por su parte, el valor moderado de Delta (0.0341) refleja que el componente estacional cambia gradualmente, lo que es consistente con la presencia de patrones estacionales que evolucionan lentamente a lo largo del tiempo.

Por el contrario, el modelo multiplicativo de Holt-Winters, aunque mostró un R^2 ligeramente inferior (0.648), presentó problemas sustanciales al no cumplir con el supuesto de normalidad de los residuos, lo que afecta su fiabilidad y limita su utilidad para la generación de pronósticos confiables. La prueba de Shapiro-Wilk aplicada a los residuos del modelo multiplicativo arrojó un valor de significancia de 0.0001, muy por debajo del nivel crítico de 0.05, lo que indica que los errores del modelo no siguen una distribución normal, comprometiendo la validez de las inferencias estadísticas y la precisión de los intervalos de confianza contruidos a partir de los pronósticos. Este hallazgo subraya la importancia de verificar los supuestos del modelo antes de utilizar sus resultados para la toma de decisiones, ya que el incumplimiento de estos supuestos puede conducir a estimaciones sesgadas y a pronósticos poco confiables. La superioridad del modelo aditivo sobre el multiplicativo sugiere que, en el caso de la serie de títulos de propiedad, la magnitud de las fluctuaciones estacionales tiende a mantenerse constante a lo largo del tiempo, independientemente del nivel gene-

ral de la serie, lo que favorece el enfoque aditivo sobre el multiplicativo. Esta característica es consistente con la naturaleza del proceso de titulación, que probablemente está sujeto a ciclos administrativos y presupuestales que generan fluctuaciones estacionales de magnitud relativamente constante, independientemente del número total de títulos entregados en cada período.

Superioridad del modelo SARIMA y cumplimiento de supuestos

La evaluación comparativa de los modelos pertenecientes a la metodología Box-Jenkins reveló una clara superioridad del modelo SARIMA sobre el modelo ARIMA tradicional, evidenciada por las métricas de error y ajuste obtenidas en el proceso de validación. El modelo ARIMA (3,1,3), con un MAPE de 33.29% y un R^2 de 0.63, demostró una capacidad predictiva limitada para capturar adecuadamente los patrones estacionales presentes en la serie, lo que sugiere que la estructura temporal de los datos requiere la incorporación explícita de componentes estacionales para lograr un ajuste satisfactorio. Esta limitación del modelo ARIMA se explica por su incapacidad para modelar las fluctuaciones periódicas que caracterizan a la serie, lo que resulta en errores de pronóstico sistemáticos que se repiten con una frecuencia estacional. La inclusión de componentes estacionales en el modelo

SARIMA permite capturar estas fluctuaciones periódicas, mejorando significativamente la precisión de los pronósticos y reduciendo los errores de ajuste. En contraste, el modelo SARIMA (3,1,3)(2,1,3)[4] alcanzó un desempeño significativamente superior, con un Error Absoluto Medio (MAE) de 25.76, un MAPE de 21.06% y un R^2 de 0.836, lo que indica que aproximadamente el 83.6% de la variabilidad en la entrega de títulos de propiedad puede ser explicada por el modelo, dejando solo un 16.4% atribuible a factores aleatorios no modelados.

Esta mejora sustancial en el ajuste y la precisión se atribuye a la capacidad del modelo SARIMA para incorporar componentes estacionales que capturan las fluctuaciones periódicas que caracterizan a la serie, lo que se traduce en una reducción significativa de los errores de pronóstico y en una mayor confiabilidad de las proyecciones generadas. La superioridad del modelo SARIMA sobre el ARIMA es consistente con los hallazgos de investigaciones previas que han demostrado que la inclusión de componentes estacionales mejora significativamente la precisión de los pronósticos en series temporales con patrones estacionales bien definidos (Box et al., 2015; Wei, 2018). La identificación de los parámetros del modelo SARIMA, con $p=3$, $d=1$, $q=3$ para la parte no estacional y $P=2$, $D=1$, $Q=3$ para la parte estacional, refleja la estructura compleja de la serie, que requiere tanto componentes autorregre-

sivos como de media móvil para capturar adecuadamente la dependencia temporal y los errores de pronóstico pasados. El valor de $d=1$ y $D=1$ indica que la serie requiere una diferenciación tanto en la parte no estacional como en la estacional para lograr la estacionariedad, lo que confirma la presencia de raíces unitarias tanto en la tendencia como en el componente estacional de la serie.

El modelo SARIMA (3,1,3)(2,1,3)[4] fue sometido a un riguroso proceso de validación que confirmó el cumplimiento de todos los supuestos fundamentales para la validez de las inferencias estadísticas, incluyendo la normalidad de los residuos, la media cero, la homocedasticidad, la independencia, la no autocorrelación y la correcta captura de la estacionalidad. La prueba de Shapiro-Wilk para la normalidad de los residuos arrojó un valor de significancia de 0.241, muy por encima del nivel crítico de 0.05, confirmando que los errores del modelo se distribuyen de manera normal y aleatoria, lo que garantiza que las pruebas de hipótesis basadas en la distribución normal sean válidas y que los intervalos de confianza construidos a partir de los pronósticos tengan la cobertura esperada. La prueba T de Student para la media de los residuos mostró un valor de significancia de 0.719, indicando que los errores no presentan sesgos sistemáticos, es decir, que en promedio el modelo no tiende a sobreestimar ni subestimar los valores de la serie, lo que es fundamental para garantizar la precisión de los pronósticos. La prueba de

Breusch-Pagan para la homocedasticidad arrojó un valor de 0.42, confirmando la constancia de la varianza de los errores a lo largo del tiempo, lo que asegura que la precisión de las predicciones sea consistente sin que existan períodos en los que los errores sean sistemáticamente mayores o menores. Adicionalmente, la prueba de CUSUM para la independencia de los residuos mostró un valor de significancia de 0.442, y la prueba de Ljung-Box para la no autocorrelación alcanzó un valor de 0.909, ambos muy por encima del nivel crítico, confirmando que los residuos son independientes y no presentan autocorrelación significativa. El correlograma estacional de los residuos evidenció la ausencia de patrones estacionales residuales, confirmando que el modelo ha capturado adecuadamente la estacionalidad de los datos.

Proyecciones trimestrales y recomendaciones para la gestión pública

Los pronósticos generados mediante el modelo SARIMA (3,1,3)(2,1,3)[4] para el período 2024-2025 proporcionan una visión detallada de las posibles fluctuaciones en la entrega de títulos de propiedad, con intervalos de confianza que permiten cuantificar la incertidumbre asociada a cada proyección. Para el primer trimestre de 2024, se estima una entrega aproximada de 298 títulos de propiedad, con un intervalo de confianza del 80% entre

244 y 352 títulos, y del 95% entre 215 y 380 títulos, lo que sugiere un nivel de actividad relativamente alto al inicio del período proyectado. Los pronósticos para los trimestres subsiguientes revelan fluctuaciones estacionales características, con picos en el segundo trimestre de 2024 (aproximadamente 337 títulos) y el segundo trimestre de 2025 (aproximadamente 319 títulos), y valles en el tercer trimestre de ambos años (140 y 160 títulos respectivamente), lo que evidencia la persistencia de los patrones estacionales identificados en el análisis histórico. Estas fluctuaciones estacionales sugieren que la entrega de títulos de propiedad en Piura sigue un patrón periódico que podría estar asociado a ciclos administrativos, disponibilidad presupuestal o factores estacionales que afectan la demanda de regularización de propiedades. La identificación de estos patrones estacionales es fundamental para la planificación institucional, ya que permite anticipar los períodos de mayor demanda y asignar recursos de manera más eficiente para satisfacer las necesidades de la población.

La amplitud de los intervalos de confianza tiende a aumentar hacia los trimestres más lejanos, reflejando una mayor incertidumbre en las proyecciones a más largo plazo, lo cual es consistente con la teoría de pronósticos que establece que la incertidumbre crece con el horizonte de predicción. Esta característica es inherente a cualquier proceso de pronóstico y debe ser considerada por los to-

madores de decisiones al evaluar la fiabilidad de las proyecciones y al diseñar planes de contingencia apropiados. La Tabla 19, que acompaña a la Figura 13, proporciona una visión cuantitativa detallada de los pronósticos y sus intervalos de confianza, permitiendo a las autoridades municipales evaluar el rango probable de variación en la entrega de títulos y tomar decisiones informadas sobre la asignación de recursos. La Figura 17, por su parte, ofrece una representación gráfica integrada que permite visualizar la continuidad entre el comportamiento histórico y las proyecciones futuras, así como la magnitud de la incertidumbre que acompaña a cada pronóstico, facilitando la identificación de los períodos donde la incertidumbre es mayor y donde, por lo tanto, se requiere una planificación más flexible.

Con base en los hallazgos obtenidos, se recomienda a la Municipalidad Provincial de Piura implementar sistemas de pronóstico basados en el modelo SARIMA seleccionado para planificar la entrega de títulos de propiedad de manera más eficiente, anticipando la demanda y asignando recursos de manera efectiva. Esta implementación debe ir acompañada del establecimiento de un protocolo sistemático para el monitoreo continuo y la actualización regular de los modelos de pronóstico, incorporando los datos más recientes y reevaluando los parámetros del modelo para asegurar que las predicciones se mantengan precisas y relevantes a lo largo del tiempo. La actuali-

zación periódica de los modelos es fundamental porque permite capturar cambios en los patrones de comportamiento de la serie, como la aparición de nuevas tendencias o la modificación de los patrones estacionales, que podrían afectar la precisión de los pronósticos si no son incorporados oportunamente. Asimismo, resulta fundamental promover la capacitación del personal municipal en técnicas de análisis estadístico y modelado de series temporales, así como incentivar la investigación en métodos de pronóstico y análisis de datos para mejorar continuamente la precisión de las predicciones y la toma de decisiones basada en evidencia. La utilización de software y herramientas tecnológicas avanzadas como Python y R, con sus respectivas librerías especializadas, proporciona plataformas robustas para el procesamiento de datos y la aplicación de modelos complejos de manera eficiente, facilitando la implementación de sistemas de pronóstico en la gestión pública. La adopción de una cultura de análisis de datos y modelado estadístico en la gestión pública permitirá a la Municipalidad Provincial de Piura mejorar significativamente su eficiencia y capacidad de respuesta a las necesidades de la comunidad, optimizando los recursos disponibles y contribuyendo al desarrollo y bienestar de la población local. La implementación de estas recomendaciones no solo mejorará la gestión de la titulación de propiedades, sino que también sentará las bases para la adopción de enfoques basados en datos en otras áreas

de la gestión municipal, promoviendo una administración pública más eficiente, transparente y orientada a resultados.

REFERENCIAS

- Abad, C. (2020). *Modelación y pronóstico de las atenciones en el servicio de hospitalización en el Hospital de la Amistad Perú – Corea II-2 Santa Rosa aplicando modelos ARIMA. Piura. Perú 2020 – 2021* [Tesis de licenciatura, Universidad Nacional de Piura].
- Abramo, P. (2021). *La ciudad informal en América Latina: desafíos y perspectivas*. Editorial Universitaria.
- Aguirre, J., & Mendoza, R. (2022). Dinámicas de ocupación informal y mercado de suelo urbano en la región Piura. *Revista de Estudios Urbanos Regionales*, 48(3), 45-68.
- Albán, A. (2023). *Pronóstico de los ingresos tributarios recaudados por SUNAT del departamento de Piura, utilizando el modelo Arima y Winters* [Tesis de licenciatura, Universidad Nacional de Piura].
- Albaladejo, M. (1994). *Derecho civil: Bienes y derechos reales*. Bosch.
- Alvarado, J., Fernández, M., & Torres, R. (2021). Pronósticos en la gestión pública: una revisión sistemática de la literatura. *Revista de Administración Pública*, 45(2), 112-135.
- Amaya Paiva, F. A., & Farfan Morales, L. M. (2025). *Pronóstico de títulos de propiedad entregados en la provincia de Piura, basados en el modelo Holt-Winters y la metodología de Box-Jenkins para el periodo 2024-2025* [Tesis de licenciatura, Universidad Nacional de Piura].
- Arechaga, D., & Bayona, G. (2022). *Pronóstico de la producción de arroz en cáscara en el Perú mediante modelos SARIMA, año 2022-2023* [Tesis de licenciatura, Universidad Nacional de Piura].
- Armstrong, J. S. (2020). *Principles of forecasting: A handbook for researchers and practitioners*. Springer.
- Avendaño, M. (2005). *Derecho de propiedad: conceptos y aplicaciones*. Editorial Jurídica Peruana.

- Baca, L. (2018). *La importancia del formato APA en la investigación académica: Guía y aplicación*. Editorial Académica.
- Bernal, C. (2016). *Metodología de la investigación*. Editorial Delfín Ltda.
- Blasetti, L. (2022). *Modelos de pronósticos de series temporales aplicados a la gestión de operaciones* [Tesis de máster, Universidad de las Illes Balears].
- Box, G., Jenkins, G., & Reinsel, C. (2008). *Time series analysis: Forecasting and control*. Prentice Hall.
- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
- Brockwell, P., & Davis, R. (2016). *Introduction to time series and forecasting*. Springer.
- Bueno, R., González, M., & Sánchez, J. (2020). Modelos predictivos en la gestión pública local. *Gestión y Política Pública*, 29(3), 45-72.
- Burnham, K., & Anderson, D. (2019). *Model selection and multimodel inference: A practical information-theoretic approach*. Springer.
- Caïs, J., Cots, L., & Formoso, C. (2014). *Investigación cualitativa longitudinal*. Cuadernos Metodológicos.
- Calderón-Cockburn, J. (2021). Informalidad y acceso al crédito en contextos urbanos. *Journal of Urban Economics*, 112(3), 67-89.
- Caroll, S. (2019). *Something deeply hidden: Quantum worlds and the emergence of spacetime*. Dutton.
- Carranza, M. (2019). *Análisis estadístico de las exportaciones de bienes en la Comunidad Andina, enero 2010 – junio 2018* [Tesis de licenciatura, Universidad Nacional de Trujillo].

- Chai, T., & Draxler, R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? *Geoscientific Model Development*, 7(3), 1247-1250.
- Chatfield, C. (2003). *The analysis of time series: An introduction*. Chapman and Hall/CRC. <https://doi.org/10.4324/9780203491683>
- Chatfield, C. (2019). *Time-series forecasting*. Chapman & Hall.
- Christou, V., & Fokianos, K. (2015). On count time series prediction. *Journal of Statistical Computation and Simulation*, 85(2), 357-373. <https://doi.org/10.1080/00949655.2013.823612>
- Chugh, A. (2020). MAE, MSE, RMSE, Coefficient of Determination, Adjusted R Squared — Which Metric is Better? Analytics Vidhya, Medium. <https://n9.cl/za7rjn>
- Clichevsky, N. (2019). Regularización de asentamientos informales en América Latina. *Revista de Urbanismo*, 40, 12-34.
- Cuadros, A. (2019). *La posesión como hecho y derecho: Un análisis sobre la seguridad en la propiedad*. Editorial Jurídica.
- De Soto, H. (2021). *El misterio del capital: Por qué el capitalismo triunfa en Occidente y fracasa en el resto del mundo*. Editorial Planeta.
- Deininger, K., & Feder, G. (2021). Land registration, governance, and development. *World Bank Research Observer*, 36(2), 145-178.
- Del Castillo, M., Rodríguez, P., & Torres, F. (2020). Formalización de la propiedad y desarrollo económico local. *Latin American Journal of Economics*, 57(1), 89-112.
- Durand-Lasserve, A., & Selod, H. (2019). Urban land markets and informal settlements. *World Bank Policy Research Working Paper*, 45(3), 78-102.

- Espinoza, R., & Ríos, M. (2022). Impacto de las políticas de formalización en la titulación de propiedades en Piura. *Revista Peruana de Economía*, 33(2), 67-89.
- Federico, G. (2020). *Titulación de tierras y desarrollo económico*. Banco Mundial.
- Fernandes, E. (2018). Regularización de asentamientos informales: experiencias comparadas. *Ciudades*, 21(2), 45-68.
- Fernández, R., & Díaz, M. (2002). *Métodos cuantitativos para la investigación: Teoría y aplicación*. Editorial Académica.
- Fildes, R., & Goodwin, P. (2021). Forecasting in public sector management. *Journal of Forecasting*, 40(4), 567-589.
- Florencia, M. (2018). *Exploración y análisis exhaustivo de los métodos estadísticos aplicados a las series de tiempo*. FCE y UNL.
- Flores, C., & Gómez, E. (2021). Transferencia metodológica en la gestión pública local. *Revista de Administración*, 34(2), 89-112.
- Gambini, M., & López, J. (2018). *Análisis de series de tiempo* [Trabajo de fin de grado, ITBA].
- Gardner, E. (2019). Exponential smoothing: The state of the art. *Journal of Forecasting*, 38(3), 245-267.
- Gardner, E., & McKenzie, E. (2019). Forecasting trends in time series. *International Journal of Forecasting*, 35(2), 567-582.
- Gilbert, A. (2012). *La ciudad latinoamericana: urbanización, pobreza y políticas públicas*. Editorial Universitaria.
- Gledhill, J. (2010). El derecho a una vivienda. *Revista de Antropología Social*, 19, 103-129.
- González, J. (2012). *La propiedad: Componentes económicos, útiles y sociales*. Editorial Jurídica.

- González-Morales, A., Pérez, J., & Santana, R. (2021). Pronósticos en la asignación de recursos públicos. *Gestión Pública*, 28(2), 123-148.
- Guerrero, M., & Medina, S. (2016). Modelos de series de tiempo. *Science Direct*, 398, 89-99.
- Hernández, R., Fernández, C., & Baptista, M. (2014). *Metodología de la investigación*. McGraw-Hill/Interamericana Editores.
- Herrera, H., Barreto, M., Tavera, E., Domador, B., Peña, J., Villalobos, D., Yarleque, C., Navarro, Y., Pozo, L., Yacsahuanca, N., & Mendoza, G. (2022). Comparison of Arima and Holt-Winters forecasting models for time series of cereal production in Peru. *AHFE International Conference. AHFE Open Access*, 22. <http://doi.org/10.54941/ahfe1001007>
- Herrera, J., & Zambrano, M. (2022). Pronósticos en servicios sociales: una revisión. *Revista de Servicios Públicos*, 19(2), 78-102.
- Herrera, M., Pérez, R., & Gómez, L. (2022). Comparación de los modelos de pronóstico ARIMA y Holt-Winters para series de tiempo de producción de cereales en el Perú en el periodo 2000-2021. *Revista Peruana de Agropecuaria*, 28(1), 45-67.
- Hyndman, R. (2020). *Forecasting: Principles and practice*. OTexts.
- Hyndman, R., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice*. OTexts.
- Hyndman, R., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice*. OTexts.
- Hyndman, R., & Koehler, A. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688.

- loris, R. (2021). Gobernanza urbana y gestión del suelo en América Latina. *Urban Studies*, 58(4), 789-812.
- Jiménez, L., & González, M. (2019). *Derecho de propiedad y su impacto en el mercado inmobiliario*. Editorial Jurídica.
- Kendall, M., & Ord, K. (2020). *Time series analysis*. Oxford University Press.
- Liu, Y., Zhang, X., & Wang, H. (2022). Forecasting public service demand using time series models. *Public Administration Review*, 82(3), 456-472.
- Ljung, G., & Box, G. (2018). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.
- Maher, C., & Zhang, Y. (2020). Predictive analytics in public administration. *Journal of Public Administration Research*, 30(2), 234-251.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74.
- Martínez, R., & Ferrada, J. (2020). Brecha entre teoría y práctica en pronósticos públicos. *Revista de Políticas Públicas*, 24(2), 89-112.
- McLeod, A., Yu, H., & Mahdi, E. (2019). Time series analysis with R. *Journal of Statistical Software*, 89(5), 1-34.
- Mejía, A., & Paez, C. (2023). *Modelos de pronóstico de producción de Rosa Freedom: Un enfoque predictivo para mejorar el cumplimiento y reducir el desperdicio en la finca María Bonita*. Universidad de la Sabana, Colombia.
- Morales, J. (2017). *La ética en la investigación académica: Transparencia y autenticidad en el manejo de la información*. Editorial Investigación.

- Mugambi, G., Ochieng, J., & Wanjiru, M. (2022). Predictive models in local governance. *African Journal of Public Administration*, 39(1), 78-102.
- Muñoz, J., & Valverde, A. (2022). Impacto de la titulación en el bienestar familiar. *Revista de Economía Social*, 28(3), 67-89.
- Pathak, P. (2021). Time series forecasting—A complete guide. Medium Analytics Vidhya. <https://n9.cl/8vjfpy>
- Patrick, S., Mirau, S., Mbalawata, I., & Leo, J. (2023). Time series and ensemble models to forecast banana crop yield in Tanzania, considering the effects of climate change. *Resources, Environment and Sustainability*, 14.
- Petropoulos, F., Makridakis, S., & Assimakopoulos, V. (2019). Forecasting with temporal hierarchies. *European Journal of Operational Research*, 277(1), 123-139.
- Petropoulos, F., Makridakis, S., & Assimakopoulos, V. (2022). The M5 competition: Forecasting with machine learning. *International Journal of Forecasting*, 38(3), 789-812.
- Ponce, C., & Torres, J. (2020). Migración y ocupación informal en la provincia de Piura. *Revista Peruana de Geografía*, 22(2), 56-78.
- Ríos, G., & Hurtado, C. (2008). *Series de tiempo*.
- Rodríguez, J., & Pérez, L. (2021). Aplicación de pronósticos en gobiernos locales. *Revista de Gestión Pública*, 32(2), 89-115.
- Rodríguez, M., & Vásquez, J. (2020). Zonas urbanas y demanda de titulación en Piura. *Estudios Regionales*, 18(1), 34-56.
- Rojas, F., & Delgado, A. (2020). Planificación pública basada en pronósticos. *Gestión Local*, 25(3), 67-89.

- Romero, R. (2021). *Apuntes de macroeconométrica*. Universidad de Costa Rica.
- Roque, E. (2022). *Predicción de la demanda de pasajeros a clústeres de estaciones del Metropolitano usando métodos de data mining, la metodología Box-Jenkins y SARIMA* [Tesis de licenciatura, Universidad de Lima].
- Rosas, R., & Morales, E. (2021). Programas de formalización en el Perú: una evaluación. *Revista de Políticas Públicas*, 29(3), 112-135.
- Ruíz, F. (2024). *Desarrollo de un modelo de pronóstico de viento de corto plazo para parques eólicos, basado en series temporales, técnicas estadísticas y machine learning*. Escuela Politécnica Nacional, Quito.
- Sánchez, A. (2020). *Métricas de error en pronósticos*. Editorial Técnica.
- Sánchez, N. (2020). *Estudio comparativo de modelos de predicción estocásticos y heurísticos aplicados a la estimación de la calidad del aire* [Tesis de maestría, Universidad de Catalunya | Educación Virtual InclusivaInicio].
- Sánchez, R., Gómez, F., & Medina, J. (2021). Delimitación territorial y análisis regional. *Estudios Geográficos*, 42(3), 89-112.
- Schwarz, G. (1978). Estimating the dimension of a model. *Annals of Statistics*, 6(2), 461-464.
- Shumway, R., & Stoffer, D. (2017). *Time series analysis and its applications*. Springer.
- Smolka, M. (2020). Informalidad urbana y políticas de suelo. *Revista de Urbanismo*, 35(2), 78-102.
- Soto, M., Gómez, P., & Fernández, L. (2020). Regularización de asentamientos en América Latina: lecciones aprendidas. *Estudios Urbanos*, 27(3), 89-112.

- Subramanian, M., Cho, J., Veerappampalayam Easwaramoorthy, S., Murugesan, A., & Chinnasamy, R. (2023). Enhancing sustainable transportation: AI-driven bike demand forecasting in smart cities. *Sustainability (Switzerland)*, 15(18). <https://doi.org/10.3390/su151813840>
- Svetunkov, I., Kourentzes, N., & Ord, K. (2020). Optimal combination of exponential smoothing models. *International Journal of Forecasting*, 36(4), 1234-1251.
- Tashman, L. (2020). Forecasting in government: Challenges and opportunities. *Journal of Public Administration*, 28(3), 145-168.
- Taylor, J. (2020). Exponential smoothing with a damped multiplicative trend. *International Journal of Forecasting*, 36(2), 345-358.
- Torero, M. (2021). *Titulación de tierras y desarrollo rural*. Instituto de Estudios Peruanos.
- Villarreal, F. (2016). *Introducción a los modelos de pronósticos*. Universidad Nacional del Sur.
- Villaverde, N. (2017). Holt Winters. <https://rpubs.com/nanrosvil/283121>
- Wang, T., Li, Q., & Chen, Y. (2021). Forecasting public sector indicators: A comparative study. *Journal of Forecasting*, 40(5), 789-812.
- Wei, W. (2006). *Time series analysis: Univariate and multivariate methods*. Pearson.
- Wei, W. (2018). *Time series analysis: Univariate and multivariate methods*. Pearson.
- Willmott, C., & Matsuura, K. (2019). On the use of dimensioned measures of error to evaluate the performance of spatial interpolators. *International Journal of Geographical Information Science*, 33(4), 789-812.

- Winters, P. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3), 324-342.
- Zevallos, A., & Rojas, F. (2021). Dinámicas territoriales en la provincia de Piura. *Revista Peruana de Desarrollo Regional*, 34(2), 67-89.
- Zhao, F., Yang, G., Yang, H., Long, H., Xu, W., Zhu, Y., Meng, Y., Han, S., & Liu, M. (2022). A method for prediction of winter wheat maturity date based on MODIS time series and accumulated temperature. *Agriculture*, 12(7). <https://doi.org/10.3390/agriculture12070945>
- Zhao, J., Li, M., & Wang, Z. (2023). Model evaluation metrics in time series forecasting. *Journal of Forecasting*, 42(2), 234-251.



Religación
Press
Ideas desde el Sur Global



Religación
Press

ISBN: 978-9907-845-09-9



9 789907 845099