



**TÍTULO DEL ESTUDIO: “DESARROLLO Y VALIDACIÓN  
DE UN ALGORITMO PREDICTIVO PARA LA  
DEMANDA EN EMERGENCIAS DE HOSPITALES NIVEL  
III DE LIMA, BASADO EN REGISTROS ELECTRÓNICOS  
DE ESSALUD (2021-2023)**

**REPORTE DE RESULTADOS DE INVESTIGACIÓN 09-2024**



**JOSHI ROSA MAGALY ACOSTA BARRIGA**  
Director de IETSI

**LELY DEL ROSARIO SOLARI ZERPA**  
Gerente de la Dirección de Investigación en Salud – IETSI

## **Autores**

- Alejandro Fabio Salvatore Aylas Barranca

## **Reporte de resultados de investigación 09-2024**

El presente reporte es el resultado de una investigación realizada en el marco de los temas de investigación en salud prioritarios para ESSALUD, para el periodo 2023-2025, aprobados con la Resolución de IETSI N°24-IETSI-2023.

## **Conflicto de intereses**

Los responsables de la elaboración del presente documento declaran no tener ningún conflicto de interés financiero o no financiero, con relación a los temas descritos en el presente documento.

## **Aprobación Ética**

El estudio fue aprobado para su ejecución por el Comité Institucional de Ética en Investigación del Hospital Nacional Guillermo Almenara Irigoyen.

## **Financiamiento**

Este documento técnico ha sido financiado por el Instituto de Evaluación de Tecnologías en Salud e Investigación (IETSI).

## **Citación**

Este documento debe ser citado como: “DESARROLLO Y VALIDACIÓN DE UN ALGORITMO DE PREDICCIÓN PARA DEMANDA DE PACIENTES EN EL SERVICIO DE EMERGENCIA EN LOS HOSPITALES DE LIMA NIVEL III DE ESSALUD: UN ESTUDIO MULTICÉNTRICO BASADO EN LOS REGISTROS ELECTRÓNICOS DE ATENCIÓN, 2021 - 2023”. Reporte de resultados de investigación xx-2024Lima: ESSALUD;2024

## **Datos de contacto**

Alejandro Fabio Salvatore Aylas Barranca

Correo electrónico: fabio.aylas.barranca@gmail.com

Teléfono: (+51) 980114131

# CONTENIDO

RESUMEN .....	4
INTRODUCCIÓN .....	5
MÉTODOS.....	6
RESULTADOS.....	7
DISCUSIÓN Y CONCLUSIONES .....	12
REFERENCIAS BIBLIOGRAFICAS .....	13
MATERIAL SUPLEMENTARIO .....	14

# RESUMEN

**OBJETIVOS:** Desarrollar y validar un algoritmo de predicción para la demanda de pacientes en el servicio de emergencia en los hospitales de Lima de nivel III de EsSalud.

**MÉTODOS:** Este estudio utiliza series temporales basadas en registros históricos de atenciones en emergencias hospitalarias para desarrollar modelos predictivos. La población incluyó pacientes mayores de 18 años atendidos en los tres principales hospitales de Lima entre enero de 2021 y agosto de 2024. Siguiendo la metodología de Knowledge Discovery in Databases (KDD), se aplicaron cinco fases principales: selección de datos relevantes, preprocesamiento para limpieza y preparación, transformación en series temporales, minería de datos para identificar patrones de tendencia y estacionalidad mediante descomposición aditiva o multiplicativa, y evaluación de modelos predictivos ARIMA/SARIMA ajustados mediante métricas como el Porcentaje de Error Medio Absoluto (MAPE).

**RESULTADOS:** Los modelos predictivos lograron un desempeño sobresaliente con valores MAPE menores a 5 % destacando el modelo SARIMA.

**CONCLUSIONES:** La elección del modelo óptimo reflejó la importancia de un análisis personalizado que considere características específicas para cada serie temporal. Sin embargo, una limitación clave fue el uso exclusivo de la demanda histórica como única variable predictiva. El uso del enfoque KDD estructuró de manera sistemática el análisis desde la selección de datos hasta la evaluación de los modelos, sentando las bases para investigaciones futuras que integren técnicas avanzadas de machine learning.

**Palabras clave:** EMERGENCIA, ARIMA, SARIMA, KNOWLEDGE DISCOVERY IN DATABASES

# INTRODUCCIÓN

Los centros de salud que atienden a pacientes en situaciones urgentes o críticas enfrentan una creciente crisis debido a que cada vez más pacientes requieren atenciones de emergencia. Este incremento sostenido supera la capacidad habitual de los sistemas hospitalarios, ya que los recursos limitados dificultan una respuesta adecuada (1). La saturación en emergencias impacta significativamente en la calidad de la atención médica, ya que genera retrasos críticos en intervenciones urgentes, con un incremento estimado del 1.5% en la mortalidad por cada hora de espera en el ingreso a cuidados intensivos (2). Este incremento sostenido genera presión a los sistemas hospitalarios para realizar estrategias efectivas para atender casos críticos de manera oportuna.

La demanda en el servicio de emergencia en los hospitales del Perú refleja una alta presencia de pacientes adultos mayores. En el Hospital Nacional Edgardo Rebagliati Martins, durante el primer trimestre de 2019, hubo una demanda de emergencia principalmente en pacientes adultos mayores, con más del 50% de ellos superando los 60 años de edad (3). El Hospital Guillermo Almenara Irigoyen experimentó una sobredemanda de pacientes en su servicio de emergencia durante el 2018, con un promedio diario de 542 (4). Este contexto subraya la urgencia de desarrollar evidencia que oriente sobre cómo manejar estos retos de manera segura, considerando especialmente la problemática de la insuficiente cantidad de profesionales de salud (5). La predicción de la demanda de atenciones en emergencia es valiosa, debido a que apoya a la planificación de personal como una forma estratégica de planificación sanitaria para el hospital (6).

Los algoritmos de predicción, como el ARIMA (modelo autoregresivo integrado de media móvil) y SARIMA (modelo autoregresivo estacional integrado de media móvil) se destacan como herramientas prometedoras. Estos modelos, al utilizar series temporales, permiten prever comportamientos futuros basándose en patrones y tendencias identificados a partir de datos históricos. ARIMA es valorado por su capacidad para modelar diversas secuencias temporales al aplicar técnicas que eliminan tendencias en los datos, permitiendo analizar patrones más claros y estables a lo largo del tiempo (7). En cambio, SARIMA agrega componentes adicionales para capturar comportamientos cíclicos en periodos regulares, como patrones mensuales o anuales.

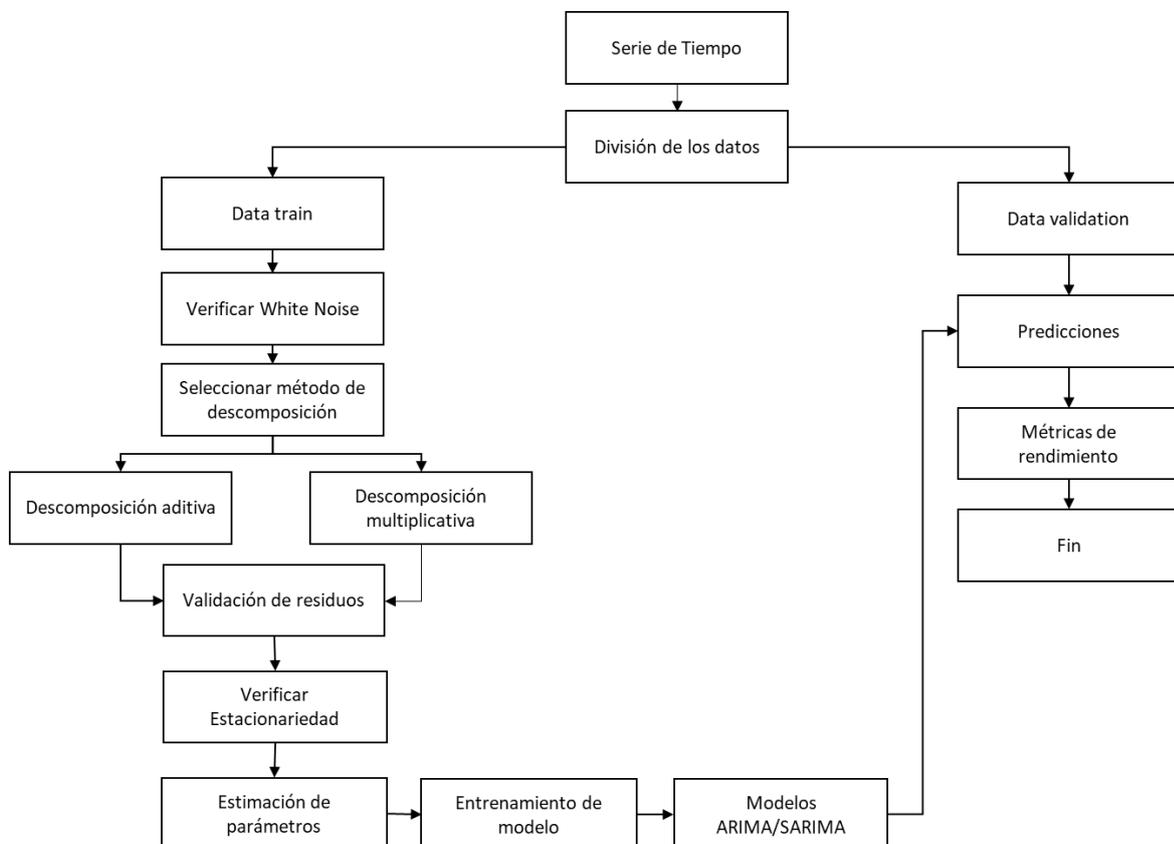
En este estudio, se desarrollaron modelos predictivos basados en series temporales para anticipar la demanda de emergencias hospitalarias en tres hospitales principales de Lima, Perú. Los hallazgos se centran en evaluar el desempeño de los modelos y en identificar las características clave que afectan su precisión.

# MÉTODOS

El presente estudio es de series de tiempo porque se trabaja con registros históricos de atenciones en emergencias hospitalarias para desarrollar modelos predictivos. La población fue conformada por pacientes de 18 años en adelante, atendidos en los centros de salud: Hospital Nacional Edgardo Rebagliati Martins (HNERM), Hospital Nacional Guillermo Almenara Irigoyen (HNGAI) y Hospital Nacional Alberto Sabogal Sologuren (HNASS) entre enero del 2021 hasta agosto del 2024.

El desarrollo metodológico sigue el enfoque de Knowledge Discovery in Databases (KDD), este consiste en la transformación de datos en información (9). La metodología tiene cinco fases: (I) selección de datos: identificación de datos relevantes para la serie de tiempo, (II) preprocesamiento: limpieza y preparación de los datos, (III) transformación: conversión de los datos en series de tiempo, (IV) minería de datos: análisis de las series temporales para identificar patrones de tendencia y estacionalidad mediante descomposición aditiva o multiplicativa, evaluando residuos y estacionariedad. Posteriormente, se entrenan modelos predictivos ARIMA/SARIMA, ajustando sus parámetros y validando su desempeño, (V) evaluación: los modelos son evaluados mediante el Porcentaje de Error Medio Absoluto (MAPE).

Figura 1. Proceso de minería de datos en el enfoque KDD para series temporales



# RESULTADOS

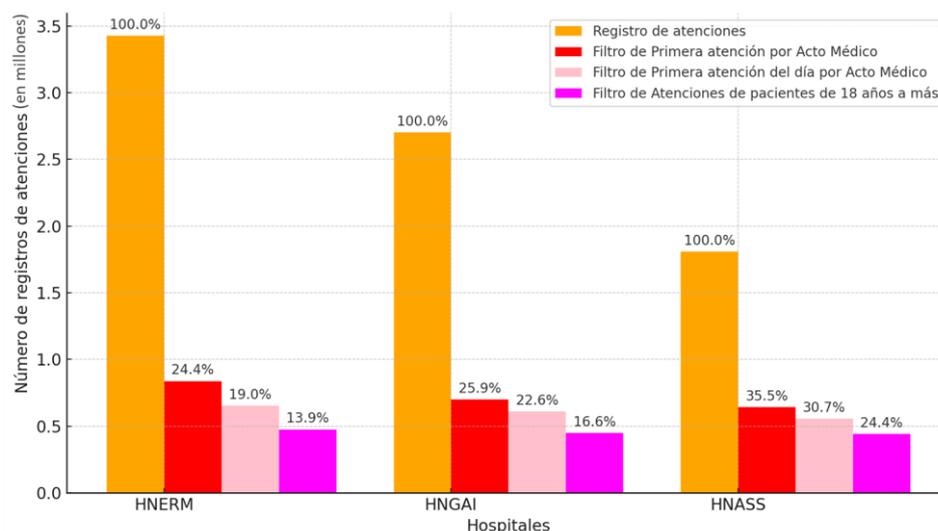
## Selección de datos

La base de datos anonimizada fue proporcionada por GCTIC. Los datos son registros de atenciones en el área de emergencia en los centros de salud mencionados. Se seleccionó seis variables: ID del paciente encriptado, Fecha y Hora de atención, Acto médico, Número de atención del Acto médico y Edad del paciente.

## Preprocesamiento de datos

Se validó que los datos de fecha, hora y edad se encuentren en el formato adecuado. Luego se revisó las inconsistencias en los registros de edad, aquellos incongruentes se consideraron como datos perdidos y se imputaron con un valor por debajo de los 18 años para mantener coherencia en el análisis de pacientes adultos. Posteriormente se aplicó filtros para registros de la primera atención de emergencia del día de paciente con edad 18 años a más. En la Figura 2, se muestra el resumen del proceso.

Figura 2. Proceso de Preprocesamiento de datos



## Transformación de datos

Se usaron los datos del preprocesamiento para construir las series temporales univariadas (conjunto de datos organizados cronológicamente que registra el comportamiento de una única variable a lo largo del tiempo). Se realizó el agrupamiento mensual para obtener el conteo total de atenciones de emergencia por mes de cada hospital. Este proceso resultó en tres series temporales: S1, correspondiente a HNERM; S2 para HNGAI; y S3 para HNASS.

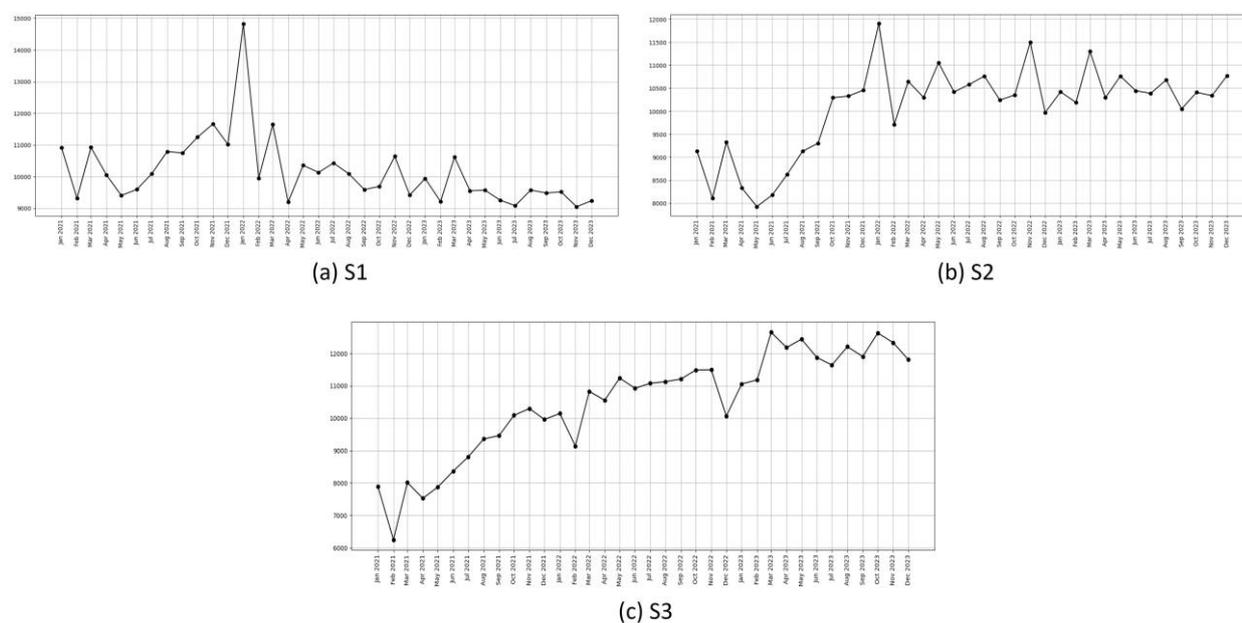
## Minería de datos

Las series se dividieron en conjunto de entrenamiento (data train) que abarcó desde enero 2021 hasta diciembre de 2023, y conjunto de validación (data validation) que comprendió de enero a agosto del 2024. Se utilizó el data train para los análisis posteriores.

Se evaluó si las series presentan comportamientos aleatorios (White Noise) utilizando la prueba de Ljung-Box, la prueba analiza si las autocorrelaciones son significativamente diferentes de cero. Los p-valor obtenidos fueron: 0.045519 para S1, 1.31E-08 para S2 y 1.04E-17 para S3. Estos resultados indican ser inferiores al nivel de significancia del 5% ( $p\text{-valor} < 0.05$ ), por lo tanto, evidencian una fuerte autocorrelación en las series, rechazando la hipótesis nula de aleatoriedad.

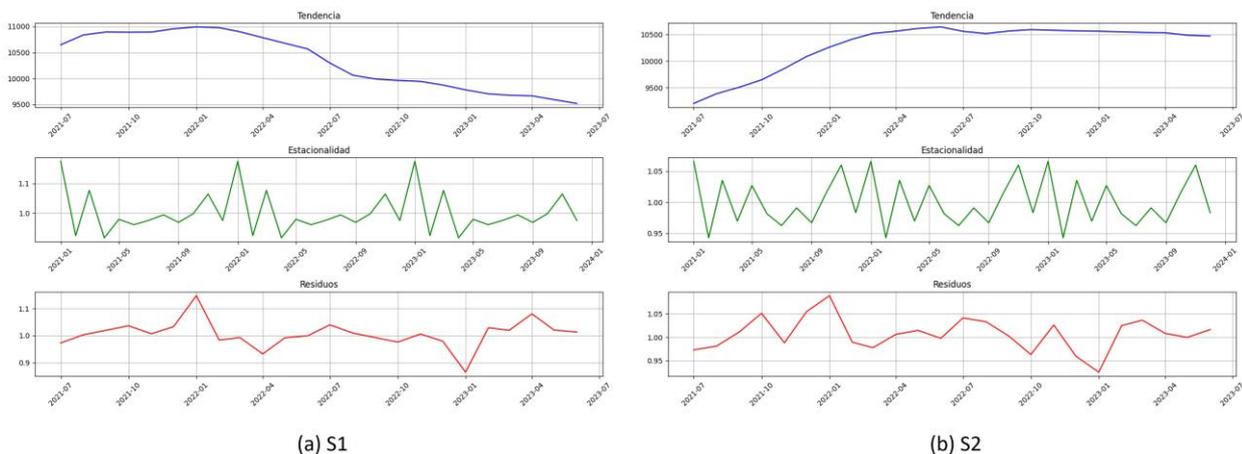
Para determinar el método de descomposición adecuado (aditiva o multiplicativa), se graficaron las curvas de las series temporales mostradas en la Figura 3.

Figura 3. Series temporales de atenciones mensuales en emergencias



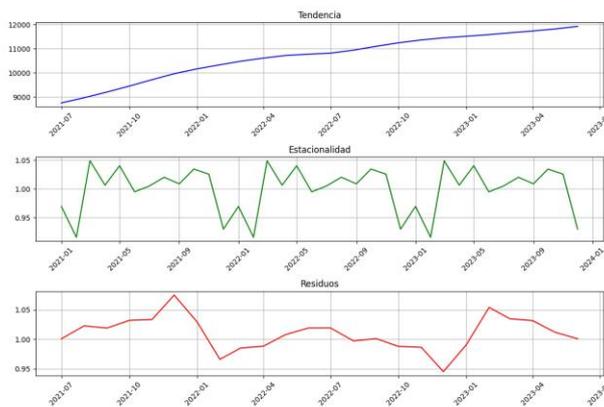
Las series evidenciaron que la varianza no es constante, ya que las atenciones por meses varían a lo largo del período. Además, la estacionalidad tampoco es constante, dado que los patrones mensuales no se repiten uniformemente en cada año. Estas características justifican el uso de la descomposición multiplicativa, como se observa en la Figura 4. La descomposición multiplicativa reveló patrones diferentes en la tendencia, estacionalidad y residuos en cada serie, siendo esencial para el diseño de los modelos ARIMA/SARIMA.

Figura 4. Descomposición multiplicativa de las series temporales



(a) S1

(b) S2



(c) S3

La validación de que los residuos muestren un patrón aleatorio es fundamental para garantizar que se ha capturado adecuadamente la estructura de la serie. Se aplicó la prueba de Ljung-Box a los residuos, obteniendo p-valores de 0.85 para S1, 0.11 para S2 y 0.15 para S3. En todos los casos, no se rechaza la hipótesis nula de aleatoriedad, lo que indica que los residuos no presentan patrones estructurados.

La estacionariedad de las series fue evaluada con la prueba Dickey-Fuller, aplicado a los datos originales y a su transformación logarítmica. Para la correcta aplicación de los modelos es crucial garantizar la estacionariedad en los datos. En caso la serie no fuera estacionaria, se calculó la primera diferenciación y se volvió a realizar la prueba.

Se utilizó la librería `auto_arima` de Python para automatizar la búsqueda de parámetros óptimos de autocorrelación ( $p$ ), diferenciación ( $d$ ), promedio móvil ( $q$ ) y sus contrapartes estacionales ( $P, D, Q$ ). Los mejores modelos fueron seleccionados en función del Criterio de Información de Akaike (AIC), eligiendo aquellos con el menor valor, ya que representa un mejor equilibrio entre la calidad del ajuste del modelo y su simplicidad.

### Evaluación de modelo:

Se usó los modelos para realizar predicciones mensuales a ocho meses. Las predicciones fueron comparadas con el data validation mediante el Porcentaje de Error Medio Absoluto (MAPE).

Tabla 1. Comparación de Modelos ARIMA/SARIMA para el HNERM

Datos	Modelo	p	d	q	P	D	Q	m	AIC	MAPE
Datos originales	Modelo 1	0	1	0	0	1	1	12	355.6	8.8
	Modelo 2	1	0	1	0	1	1	12	376.4	5.2
Datos con transformación logarítmica	Modelo 3	1	1	0	1	0	0	12	-90.9	9.3
	Modelo 4	1	0	0	1	0	0	12	-84	3.1

Los resultados de la Tabla 1 muestran que el modelo 4 fue el más preciso, logrando el menor error al comparar las predicciones con los datos reales (MAPE de 3.1%). Este modelo utiliza características específicas de los datos históricos para realizar pronósticos efectivos. No fue necesario ajustar por grandes cambios en la tendencia a largo plazo ( $d = 0$ ), y no incluyó componentes que promedian cambios erráticos en los datos ( $q = 0$ ). Sin embargo, identificó que la demanda histórica tiene un patrón repetitivo influenciado por valores previos, lo que se captura mediante un término autoregresivo ( $p = 1$ ). En cuanto a los patrones estacionales, el modelo también incluyó un término autoregresivo estacional ( $P = 1$ ) que refleja cómo los datos actuales están relacionados con los datos del mismo periodo en años anteriores, sin necesidad de ajustes adicionales por cambios estacionales drásticos ( $D = 0$ ). Además, la periodicidad ( $m = 12$ ) confirma que la demanda sigue un ciclo anual, lo que permite identificar patrones regulares mes a mes.

Tabla 2. Comparación de Modelos ARIMA/SARIMA para el HNGAI

Datos	Modelo	p	d	q	P	D	Q	m	AIC	MAPE
Datos originales	Modelo 1	0	1	2	2	1	0	12	370.1	41.2
	Modelo 2	1	0	1	0	1	0	12	393	4
Datos con transformación logarítmica	Modelo 3	1	1	0	0	0	0	12	-89.9	4.1
	Modelo 4	2	0	0	0	0	0	12	-89.3	5.4

Los resultados de la Tabla 2 indican que el modelo 2 y el modelo 3 tuvieron el mejor desempeño, con un error muy bajo en sus predicciones (MAPE de 4.0% y 4.1%, respectivamente). El modelo 2, basado en datos originales, es un modelo SARIMA. Este utiliza un término autoregresivo ( $p = 1$ ) para capturar cómo

los datos actuales están influenciados por los valores previos. No requiere ajustes por grandes cambios en la tendencia a largo plazo ( $d = 0$ ) y emplea un componente de medias móviles ( $q = 1$ ) para manejar fluctuaciones irregulares en los datos. Además, incluye un término estacional ( $Q = 1$ ) con periodicidad anual ( $m = 12$ ), lo que permite identificar patrones cíclicos que se repiten mensualmente. Por otro lado, el modelo 3, ajustado con datos transformados logarítmicamente, es un modelo ARIMA. Este modelo utiliza un término autoregresivo ( $p = 1$ ) para captar patrones históricos, pero sin incluir un componente de medias móviles ( $q = 0$ ). La periodicidad estacional ( $m = 12$ ) sigue siendo clave para identificar patrones repetitivos a lo largo del año. La transformación logarítmica permitió estabilizar las variaciones en los datos, mejorando la claridad de los patrones subyacentes.

Tabla 3. Comparación de Modelos ARIMA/SARIMA para el HNASS

Datos	Modelo	p	d	q	P	D	Q	m	AIC	MAPE
Datos originales	Modelo 1	0	1	0	0	1	0	12	405.0	3.9
	Modelo 2	1	0	0	0	1	0	12	411.3	6.4
Datos con transformación logarítmica	Modelo 3	2	0	0	0	0	0	12	-72.8	5.6
	Modelo 4	1	1	0	0	0	0	12	-70.7	3.8

Los resultados de la Tabla 3 indican que los mejores modelos para la serie son el modelo 1 (con datos originales) y el modelo 4 (con transformación logarítmica) con valores MAPE de 3.9% y 3.8%, respectivamente. El modelo 1 es un modelo SARIMA que incluye un componente de diferenciación estacional ( $D = 1$ ), lo cual permite manejar las fluctuaciones cíclicas anuales de la serie. Además, este modelo no requiere términos autoregresivos ni de medias móviles en los componentes no estacionales ( $p = 0, q = 0$ ), lo que sugiere que las variaciones a corto plazo no son significativas en los datos originales. Por su parte, el modelo 4, también un modelo SARIMA, trabaja sobre datos transformados logarítmicamente, lo que facilita la estabilización de las variaciones y mejora la precisión del ajuste. Este modelo incorpora un término autoregresivo no estacional ( $p = 1$ ) y una diferenciación no estacional ( $d = 1$ ), lo que le permite manejar tanto patrones históricos como tendencias en los datos. En los componentes estacionales, no requiere diferenciación adicional ( $D = 0$ ), reflejando una periodicidad anual ( $m = 12$ ) inherente a la serie.

## DISCUSIÓN Y CONCLUSIONES

En el presente estudio, se construyeron modelos predictivos basados en series temporales para pronosticar la demanda de emergencias hospitalarias en tres centros de salud de Lima. Nuestros hallazgos principales indican que los modelos SARIMA, ajustados con datos transformados logarítmicamente, lograron un mejor desempeño en precisión con valores MAPE menor a 5%. Sin embargo, la elección del modelo óptimo dependió de las características específicas de cada serie, lo que subraya un enfoque personalizado en el análisis de datos hospitalarios. Estos resultados representan un avance inicial y resaltan que es posible realizar predicciones factibles utilizando datos históricos.

El estudio proporciona conocimiento sobre el proceso de diseño de predicción con series temporales para demanda de emergencia. Se destaca la importancia de técnicas de descomposición de las series para identificar patrones estacionales y tendencias en los datos, garantizando que la información proporcionada sea adecuada para realizar pronósticos confiables. Por último, el uso del enfoque KDD asegura que el análisis sea sistemático, desde la selección de los datos hasta la evaluación de los modelos, estableciendo una base sólida para futuras investigaciones en el área.

La limitación del estudio radica en el uso de una sola variable (demanda histórica) para el modelo predictivo, omitiendo otras variables independientes que podrían influir en la demanda de pacientes. Diversos estudios han mostrado que la inclusión de múltiples variables puede mejorar la precisión de los modelos de pronósticos. Entre ellos destacan las variables sociodemográficas, como la edad, el sexo, el estado civil y la ubicación geográfica; factores clínicos, como la presencia de enfermedades crónicas, comorbilidades y antecedentes de hospitalización; y elementos externos, como la estacionalidad, los cambios climáticos, la contaminación ambiental, los eventos sociales o epidemiológicos, y las condiciones económicas, también se consideran aspectos relacionados con la accesibilidad a los servicios de salud, como la cobertura médica, la distancia al hospital y las barreras culturales (10). En futuros trabajos, la incorporación de estas variables podría transformar los modelos predictivos en herramientas más robustas que integren técnicas más avanzadas de machine learning para capturar mejor la complejidad de la demanda hospitalaria y optimizar la precisión de los pronósticos.

En conclusión, creemos que pronosticar el número de pacientes que llegarán a las emergencias de los hospitales ayudará a obtener un panorama claro sobre la cantidad de recursos mensuales necesarios para su atención. Sin embargo, no se trata solo de producir buenos pronósticos, sino de garantizar que estos sean útiles para mejorar la atención al paciente. El modelo no debe juzgarse únicamente por métricas de error como el MAPE, sino también por su capacidad para informar decisiones estratégicas

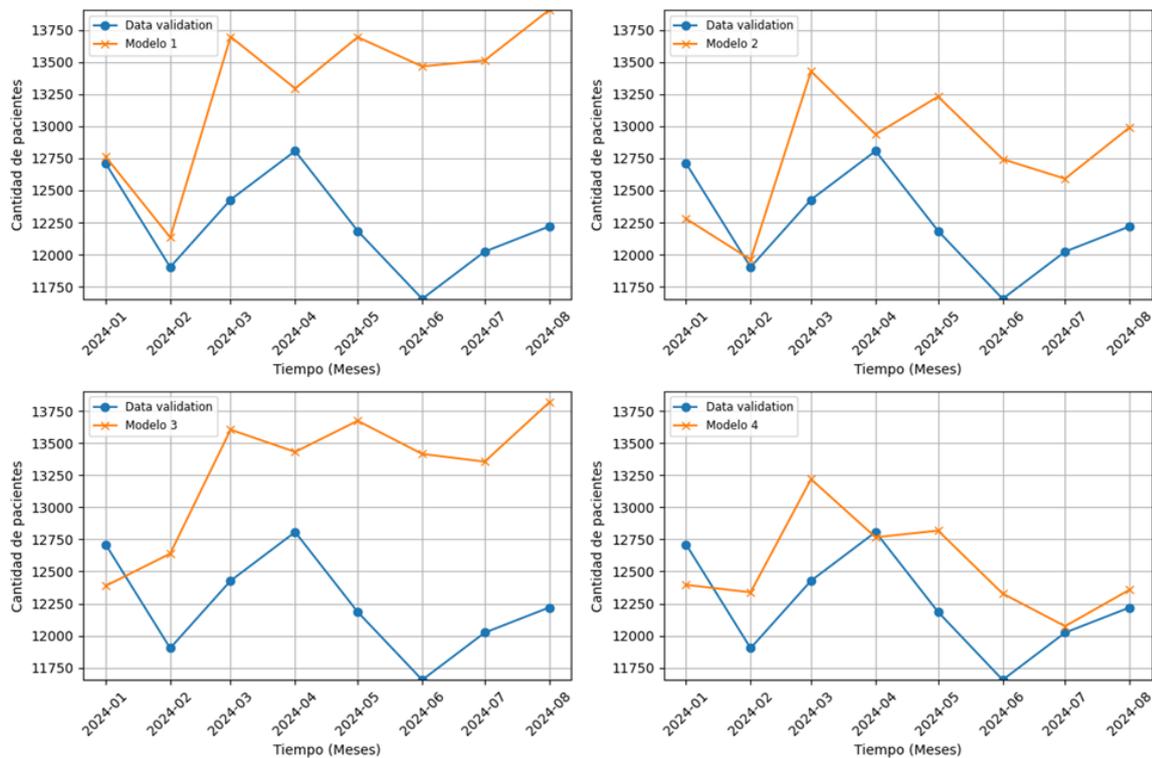
que optimicen la asignación de recursos, reduzcan tiempos de espera y, en última instancia, contribuyan a una experiencia más eficiente y humana para los pacientes.

## REFERENCIAS BIBLIOGRAFICAS

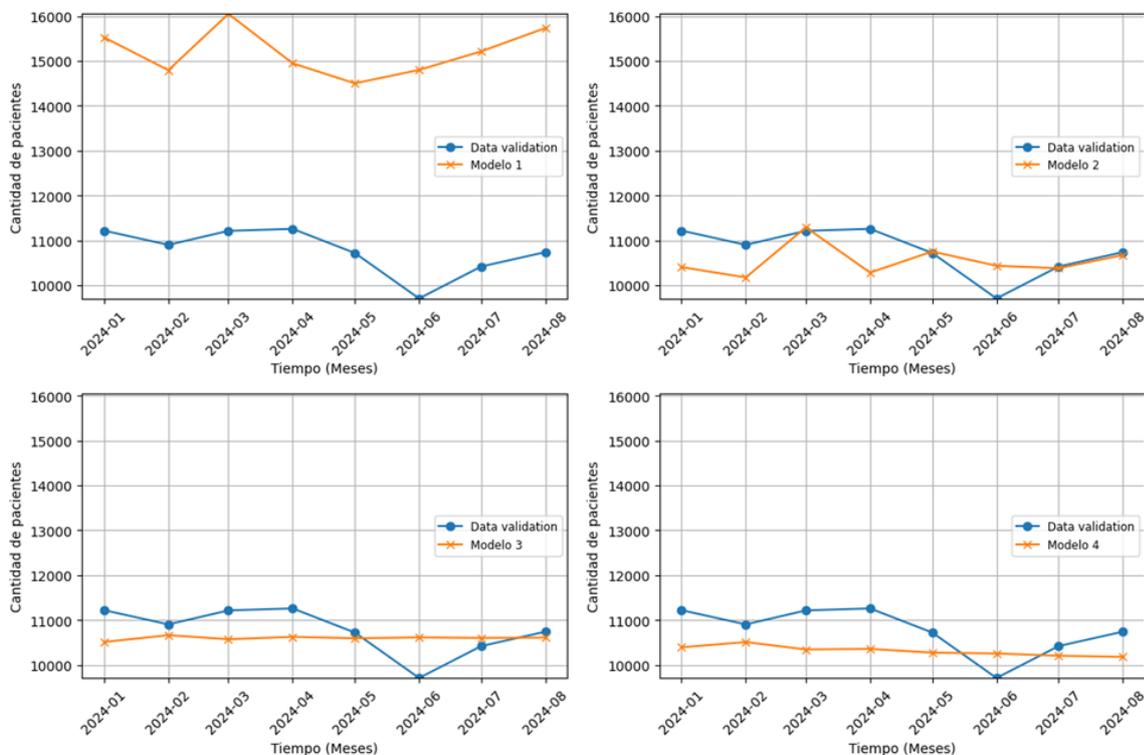
1. Berchet C. Emergency Care Services: Trends, Drivers and Interventions to Manage the Demand [Internet]. Paris: OECD; 2015 ago [citado 7 de febrero de 2024]. Disponible en: [https://www.oecd-ilibrary.org/social-issues-migration-health/emergency-care-services\\_5jrts344crns-en](https://www.oecd-ilibrary.org/social-issues-migration-health/emergency-care-services_5jrts344crns-en)
2. Anquela Gracia R, Jiménez Ramos I, Carreras Palacio P, Galduroz Arcelus M, Pérez Albors C. Saturación en los servicios de urgencias, causas y consecuencias. *Revista Sanitaria de Investigación*. 2021;2(5 (Mayo 2021)):138.
3. Taype-Huamaní W, Miranda-Soler D, Castro-Coronado L, Amado-Tineo J, Taype-Huamaní W, Miranda-Soler D, et al. Saturación y hacinamiento del servicio de emergencia de un hospital urbano. *Revista de la Facultad de Medicina Humana*. abril de 2020;20(2):216-21.
4. Farfán Bernales AA. Análisis situacional del servicio de emergencia del Hospital Nacional Guillermo Almenara 2019 Lima - Perú. Universidad Nacional Federico Villarreal [Internet]. 2021 [citado 7 de febrero de 2024]; Disponible en: <http://repositorio.unfv.edu.pe/handle/20.500.13084/5106>
5. Cooper A, Davies F, Edwards M, Anderson P, Carson-Stevens A, Cooke MW, et al. The impact of general practitioners working in or alongside emergency departments: a rapid realist review. *BMJ Open*. 1 de abril de 2019;9(4):e024501.
6. Champion R, Kinsman LD, Lee GA, Masman KA, May EA, Mills TM, et al. Forecasting emergency department presentations. *Aust Health Review*. 2007;31(1):83.
7. Shumway RH, Stoffer DS. ARIMA Models. En: Shumway RH, Stoffer DS, editores. *Time Series Analysis and Its Applications: With R Examples* [Internet]. Cham: Springer International Publishing; 2017 [citado 7 de febrero de 2024]. p. 75-163. (Springer Texts in Statistics). Disponible en: [https://doi.org/10.1007/978-3-319-52452-8\\_3](https://doi.org/10.1007/978-3-319-52452-8_3)
8. Murtas R, Tunesi S, Andreano A, Russo AG. Time-series cohort study to forecast emergency department visits in the city of Milan and predict high demand: a 2-day warning system. *BMJ Open*. 1 de abril de 2022;12(4):e056017.
9. Fayyad U, Piatetsky-Shapiro G, Smyth P. From Data Mining to Knowledge Discovery in Databases. *AI Magazine*. 15 de marzo de 1996;17(3):37-37.
10. He J, Hou X yu, Toloo S, Patrick JR, Fitz Gerald G. Demand for hospital emergency departments: a conceptual understanding. *World J Emerg Med*. 2011;2(4):253-61.

# MATERIAL SUPLEMENTARIO

FS1. Comparación de las curvas de los modelos ARIMA/SARIMA de HNERM



FS2. Comparación de las curvas de los modelos ARIMA/SARIMA de HNGAI



FS3. Comparación de las curvas de los modelos ARIMA/SARIMA de HNASS

