

# UNIVERSIDAD TÉCNICA DE AMBATO



## FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E INDUSTRIAL

### MAESTRÍA EN MATEMÁTICA APLICADA

---

#### TEMA: MODELO PROSPECTIVO PARA DETERMINAR LA OCUPACIÓN DE CAMAS EN EL HOSPITAL IESS PUYO

---

Trabajo de titulación previo a la obtención del Título de Cuarto Nivel de Magíster en Matemática Aplicada

Modalidad del Trabajo de Titulación: Proyecto de Desarrollo

**Autor:** Ing. Christian Gabriel Gavilanes Valencia, MSc.

**Director:** Dr. Freddy Geovanny Benalcázar Palacios, Mg.

Ambato – Ecuador  
2023

A la Unidad Académica de Titulación de la Facultad de Ingeniería en Sistemas,  
Electrónica e Industrial.

El Tribunal receptor del Trabajo de Titulación, presidido por: la Ingeniera Elsa Pilar Urrutia Urrutia Magíster, e integrado por los señores: Ingeniero Fabián Rodrigo Salazar Escobar, PhD; Ingeniera Clara Augusta Sánchez Benítez, Magíster., designados por la Unidad Académica de Titulación de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial de la Universidad Técnica de Ambato, para receptor el Trabajo de Titulación con el tema: “Modelo Prospectivo para Determinar la Ocupación de Camas en el Hospital IESS Puyo” elaborado y presentado por el Ingeniero Christian Gabriel Gavilanes Valencia, para optar por el Título de cuarto nivel de Magíster en Matemática Aplicada; una vez escuchada la defensa oral del Trabajo de Titulación, el Tribunal aprueba y remite el trabajo para uso y custodia en las bibliotecas de la UTA.

-----  
Ing. Elsa Pilar Urrutia Urrutia, Mg.  
**Presidente y Miembro del Tribunal**

-----  
Ing. Fabián Rodrigo Salazar Escobar, PhD.  
**Miembro del Tribunal**

-----  
Ing. Clara Augusta Sánchez Benítez, Mg.  
**Miembro del Tribunal**

## **AUTORÍA DEL TRABAJO DE TITULACIÓN**

La responsabilidad de las opiniones, comentarios y críticas emitidas en el trabajo de Titulación presentado con el tema: “Modelo Prospectivo para Determinar la Ocupación de Camas en el Hospital IESS Puyo”, le corresponde exclusivamente a: Ingeniero, Christian Gabriel Gavilanes Valencia, autor bajo la dirección del Doctor Freddy Geovanny Benalcázar Palacios, Magíster director del Trabajo de Investigación; y el patrimonio intelectual le pertenece a la Universidad Técnica de Ambato.

-----  
Ing. Christian Gabriel Gavilanes Valencia, MSc.  
C.C. 1600642613  
**AUTOR**

-----  
Dr. Freddy Geovanny Benalcázar Palacios, Mg.  
C.C. 1802535888  
**DIRECTOR**

## **DERECHOS DE AUTOR**

Autorizo a la Universidad Técnica de Ambato, para que el Trabajo de Titulación, sirva como un documento disponible para su lectura, consulta y procesos de investigación, según las normas de la Institución.

Cedo los Derechos de mi trabajo, con fines de difusión pública, además apruebo la reproducción de este, dentro de las regulaciones de la Universidad.

-----  
Ing. Christian Gabriel Gavilanes Valencia, MSc.  
C.C. 1600642613

## ÍNDICE GENERAL DE CONTENIDOS

PORTADA .....	i
A LA UNIDAD ACADÉMICA DE TITULACIÓN .....	ii
AUTORÍA DEL TRABAJO DE TITULACIÓN .....	iii
DERECHOS DE AUTOR .....	iv
ÍNDICE GENERAL DE CONTENIDOS .....	v
ÍNDICE DE TABLAS .....	vii
ÍNDICE DE FIGURAS .....	ix
AGRADECIMIENTO .....	x
DEDICATORIA .....	xi
RESUMEN EJECUTIVO .....	xii
CAPÍTULO I .....	14
EL PROBLEMA DE INVESTIGACIÓN .....	14
1.1. INTRODUCCIÓN .....	14
1.2. JUSTIFICACIÓN .....	14
1.3. OBJETIVOS .....	15
1.3.1. Objetivo general .....	15
CAPÍTULO II .....	17
ANTECEDENTES INVESTIGATIVOS .....	17
2.1. ESTADO DEL ARTE .....	17
2.2. FUNDAMENTACIÓN TEÓRICA .....	21
2.2.1. Modelos Estadísticos .....	21
2.2.2. Proceso estocástico .....	26
2.2.3. Series de tiempo .....	27
2.2.4. Hospital IESS Puyo .....	34
CAPÍTULO III .....	36
MARCO METODOLÓGICO .....	36
3.1. UBICACIÓN .....	36
3.1.1. Caracterización geográfica .....	37
3.1.2. Descripción de la ubicación geográfica .....	37
3.1.3. Accesibilidad .....	37
3.1.4. Límites .....	37
3.2. EQUIPOS Y MATERIALES .....	38

3.3.	TIPO DE INVESTIGACIÓN .....	38
3.4.	PRUEBA DE HIPÓTESIS .....	39
3.5.	POBLACIÓN Y MUESTRA.....	39
3.5.1.	Población .....	39
3.5.2.	Muestra .....	39
3.6.	RECOLECCIÓN DE INFORMACIÓN .....	40
3.7.	PROCESAMIENTO Y ANÁLISIS ESTADÍSTICO .....	40
3.7.1.	Procesamiento.....	40
3.7.2.	Análisis estadístico .....	40
3.8.	VARIABLES RESPUESTA O RESULTADOS ALCANZADOS.....	44
3.8.1.	Variables respuesta .....	44
3.8.2.	Resultados alcanzados .....	44
CAPÍTULO IV .....		46
RESULTADOS Y DISCUSIÓN .....		46
4.1.	INTRODUCCIÓN .....	46
4.2.	VARIABLES Y ESTRUCTURA DE LA BASE DE DATOS .....	46
4.3.	MODELADO DE LA OCUPACIÓN DE CAMAS EN EL ÁREA DE HOSPITALIZACIÓN SEGÚN LA METODOLOGÍA BOX-JENKINS .....	47
4.3.1.	Identificación del modelo .....	47
4.3.2.	Evaluación del modelo .....	56
4.4.	MODELADO DE LA OCUPACIÓN DE CAMAS EN EL ÁREA DE EMERGENCIAS SEGÚN LA METODOLOGÍA BOX-JENKINS.....	63
4.4.1.	Identificación del modelo .....	63
4.4.2.	Estimación de los parámetros del modelo .....	71
4.4.3.	Evaluación del modelo .....	72
4.4.4.	Predicción a través de la simulación del modelo desarrollado para el área de emergencia.....	76
4.5.	DISCUSIÓN DE RESULTADOS .....	79
CAPÍTULO V .....		81
CONCLUSIONES Y RECOMENDACIONES .....		81
5.1.	CONCLUSIONES .....	81
5.2.	RECOMENDACIONES.....	83
5.3.	Referencias.....	84
5.4.	ANEXOS .....	88

## ÍNDICE DE TABLAS

		Pág.
Tabla 1.	Descripción geográfica del Hospital	37
Tabla 2.	Matriz de consistencia de variables	45
Tabla 3.	Estructura de la base de datos	46
Tabla 4.	Test de Dickey – Fuller	49
Tabla 5.	Test Dickey-Fuller de la serie diferenciada	51
Tabla 6.	Modelos ARIMA propuestos	52
Tabla 7.	Modelo SARIMA propuestos	52
Tabla 8.	Estimación de parámetros para el modelo SARIMA (0, 1, 0) (1, 0, 0) [12]	54
Tabla 9.	Estimación de parámetros para el modelo SARIMA (1, 1, 1) (1, 0, 3) [12]	54
Tabla 10.	Significancia de los parámetros modelo SARIMA (0, 1, 0) (1, 0, 0) [12].	55
Tabla 11.	Significancia de los parámetros del modelo SARIMA (1, 1, 1) (1, 0, 3) [12].	55
Tabla 12.	Test de Dickey-Fuller para los residuos del modelo SARIMA	59
Tabla 13.	Test de Ljung-Box para los residuos del modelo SARIMA Test de Kolmogorov-Smirnov para los residuos del modelo	59
Tabla 14.	SARIMA	60
Tabla 15.	Comparación entre los datos de entrenamiento y testeo Pronóstico de la ocupación de camas en el área de	61
Tabla 16.	hospitalización	62
Tabla 17.	Test de Dickey – Fuller	66
Tabla 18.	Test de Dickey-Fuller para la serie con una diferenciación	67
Tabla 19.	Modelo ARIMA propuestos	69
Tabla 20.	Modelo SARIMA propuestos	69
Tabla 21.	Estimación de parámetros para el modelo SARIMA (1, 1, 1) (1, 0, 2) [12].	71
Tabla 22.	Significancia de los parámetros del modelo SARIMA (1, 1, 1) (1, 0, 2) [12]	72
Tabla 23.	Test de Dickey-Fuller para probar estacionariedad de los residuos	74
Tabla 24.	Test de Ljung-Box para los residuos.	75
Tabla 25.	Prueba de normalidad para los residuos	76
Tabla 26.	Comparación entre los datos de entrenamiento y testeo.	77
Tabla 27.	Pronóstico del modelo SARIMA(1,1,1)(1,0,2)[12]	78
Tabla 28.	Estimación de parámetros del modelo ARIMA (1,1,0)	88
Tabla 29.	Estimación de los parámetros del modelo ARIMA (1,1,1)	88
Tabla 30.	Significancia de los parámetros del modelo ARIMA (1,1,0)	89
Tabla 31.	Significancia de los parámetros del modelo ARIMA (1,1,1). Test de Dickey-Fuller para los residuos del modelo ARIMA	89
Tabla 32.	(1,1,1).	92
Tabla 33.	Test de Ljung-Box para los residuos del modelo ARIMA (1,1,1)	92

Tabla 34.	Prueba de normalidad para los residuos del modelo ARIMA (1,1,1)	93
Tabla 35.	Estimación de los parámetros del modelo ARIMA (1,0,0).	95
Tabla 36.	Estimación de los parámetros del modelo ARIMA (2,0,2)	95
Tabla 37.	Significancia de los parámetros del modelo ARIMA (1,0,0).	96
Tabla 38.	Significancia de los parámetros del modelo ARIMA (2,0,2).	96
Tabla 39.	Test de Ljung_Box para los residuos del modelo ARIMA (1,0,0). Test de Dickey-Fuller para los residuos del modelo ARIMA	99
Tabla 40.	(1,0,0).	99
Tabla 41.	Prueba de normalidad para los residuos del modelo ARIMA (1,0,0).	100

## ÍNDICE DE FIGURAS

		Pág.
Figura 1.	Hospital Básico IESS Puyo	36
Figura 2	Metodología Box-Jenkins	41
Figura 3	Serie de tiempo de la ocupación de camas en el área de hospitalización	47
Figura 4	Descomposición de la serie correspondiente a la ocupación de camas	48
Figura 5	Funciones de autocorrelación simple (ACF) y parcial (PACF)	48
Figura 6	Serie de tiempo de ocupación de camas estacionaria	50
Figura 7	Componentes de la serie de ocupación de camas estacionaria	50
Figura 8	Correlogramas ACF y PACF para la serie original y diferenciada	51
Figura 9	Análisis gráfico del modelo SARIMA (1, 1, 1) (1, 0, 3) [12]	57
Figura 10	Diagnóstico del modelo SARIMA	58
Figura 11	Comparación de la serie original con los valores ajustados por el modelo SARIMA	61
Figura 12	Pronósticos	63
Figura 13	Serie de tiempo de la ocupación de camas en el área de emergencia	64
Figura 14	Descomposición de la serie en sus componentes	64
Figura 15	Funciones de autocorrelación simples (ACF) y parcial (ACF) de la serie	65
Figura 16	Serie de tiempo diferenciada una vez	66
Figura 17	Descomposición de la serie con una diferenciación	67
Figura 18	Funciones de autocorrelación simple y parcial de la serie original y con una diferenciación	68
Figura 19	Análisis gráfico de los residuos del modelo SARIMA (1,1,1)(1,0,2).	73
Figura 20	Diagnóstico de los residuos	74
Figura 21	Comparación de la serie original con los valores ajustados por el modelo SARIMA	77
Figura 22	Pronóstico para la ocupación de camas para el año 2023	79
Figura 23	Análisis de los residuos del modelo ARIMA (1,1,1)	90
Figura 24	Diagnóstico de los residuos del modelo ARIMA (1,1,1).	91
Figura 25	Pronóstico con el modelo ARIMA (1,1,1).	94
Figura 26	Análisis de los residuos del modelo ARIMA (1,0,0).	97
Figura 27	Diagnóstico de los residuos del modelo ARIMA (1,0,0)	98
Figura 28	Pronóstico del modelo ARIMA (1,0,0)	101

## **AGRADECIMIENTO**

En primer lugar, agradezco a Dios, quien es mi guía y mi fuerza.

A la Universidad Técnica de Ambato con su Centro de Posgrados por darme la oportunidad de continuar superándome profesionalmente.

A la Facultad de Ingeniería en Sistemas, Electrónica e Industrial por acogerme en sus aulas y ser partícipe activo de la educación que ofrece en su seno.

Al Dr. Freddy Geovanny Benalcázar Palacios Mg., director del trabajo de titulación, quien con su sapiencia supo orientarme oportuna y efectivamente en el desarrollo de mi investigación.

A todos quienes me apoyaron en las diferentes circunstancias que atravesé en este trayecto de posgrado.

Christian G. Gavilanes V.

## **DEDICATORIA**

Dedico este proyecto de investigación a Dios  
que ha sido mi guía en el camino de formación,  
a mis padres Myrian y Gabriel,  
y a mi familia en general quienes han sido  
un apoyo incondicional y mi ejemplo para seguir.

Christian G. Gavilanes V.

**UNIVERSIDAD TÉCNICA DE AMBATO**  
**FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E**  
**INDUSTRIAL**  
**MAESTRÍA EN MATEMÁTICA APLICADA**  
**COHORTE 2021**

**TEMA:**

**“MODELO PROSPECTIVO PARA DETERMINAR LA OCUPACIÓN DE  
CAMAS EN EL HOSPITAL IESS PUYO”**

**MODALIDAD DE TITULACIÓN:** Proyecto de Desarrollo

**AUTOR:** Ing. Christian Gabriel Gavilanes Valencia, MSc

**DIRECTOR:** Dr. Freddy Geovanny Benalcázar Palacios Mg.

**FECHA:** 26 de enero del 2023

**RESUMEN EJECUTIVO**

La emergencia sanitaria iniciada en el año 2020 por el COVID -19 afectó en todos los ámbitos a la humanidad; encontrando un sistema sanitario fragmentado, ante esta situación se han tomado diferentes acciones, y como una manera de aportar a la reactivación se plantea un estudio investigativo bajo el tema: “Modelo Prospectivo para determinar la ocupación de camas en el Hospital IESS Puyo”, este estudio estadístico se basó en series de tiempo por ser el óptimo para predecir el comportamiento a futuro de la ocupación de camas en el hospital. Una vez construido y aplicado el programa, se seleccionó el mejor modelo SARIMA para la ocupación de camas en las áreas de hospitalización y emergencia; para ello se utilizó la metodología Box-Jenkins para analizar la serie de tiempo correspondiente a la ocupación de camas en las dos áreas del Hospital en el periodo comprendido entre enero 2018 – septiembre 2022. Las variables usadas para la construcción de los modelos matemáticos fueron como variable dependiente la ocupación de camas y como variable independiente el tiempo. Para verificar la estacionariedad de las series de tiempo se procedió a descomponer cada una de las series en sus cuatro componentes (datos observados, tendencia, estacionalidad y

aleatoriedad). Se realizó el test de Dickey Fuller y se graficaron las funciones de correlación simple y parcial para comprobar la presencia de raíces unitarias utilizándose un nivel de significancia de 0.05. Los resultados alcanzados en la presente investigación son dos modelos prospectivos, el modelo SARIMA (1,1,1) (1,0,3) se ajusta adecuadamente a la serie de tiempo de ocupación de camas en el área de hospitalización del Hospital Básico IESS Puyo, cuya estimación arrojó como ecuación de pronóstico:  $\Delta Y_t = -0.79034 Y_{t-1} + \epsilon_t$ . Para el área de emergencias se desarrolló un modelo SARIMA (1,1,1) (1,0,2), cuya ecuación de pronóstico es:  $\Delta Y_t = 0.759401 Y_{t-1} + 0.963401 Y_{t-12} + 0.999998 \epsilon_{t-1} + \epsilon_t$ , dichos modelos prospectivos encontrados permiten tener un pronóstico efectivo a mediano plazo. Al comparar los datos de testeo con los obtenidos del entrenamiento se encontró que la eficacia de los modelos del área de hospitalización y emergencia fue de 87.16% y 88.61%, respectivamente. Estos parámetros van a permitir al personal del Hospital optimizar recursos y brindar una atención de calidad a los usuarios del hospital.

**DESCRIPTORES:** COVID-19, HOSPITAL, METODOLOGÍA BOX-JENKINS, PRONÓSTICO, SARIMA, SERIE DE TIEMPO, TEST DE DICKEY FULLER.

## **CAPÍTULO I**

### **EL PROBLEMA DE INVESTIGACIÓN**

#### **1.1. INTRODUCCIÓN**

El presente trabajo es el fruto de una necesidad surgida durante la pandemia del COVID19 iniciada en el año 2020. Sin duda, la compleja situación por la que atravesamos dejó al descubierto las falencias en la humanidad y sorprendió de sobremana a la atención que se brindaba en el sector salud. Es así que para apoyar en la solución a los inconvenientes surgidos se desarrolló la investigación bajo el Título “Modelo prospectivo para determinar la ocupación de camas en el hospital IESS Puyo”.

Para ejecutar la tarea, se hizo una investigación de campo junto a la de tipo bibliográfica con los aportes de la innovación educativa respecto a lo digital, con ello se organizó el trabajo y se diseñó el programa estadístico de operacionalización de variables considerando las series de tiempo, donde en forma estructurada se representan los datos y se puede obtener un pronóstico a mediano plazo en el que se pueda estimar la demanda de camas y con ello poder determinar la cantidad de camas que debe tener a disponibilidad el hospital, para poder optimizar recursos y fortalecer la atención a los pacientes, coadyuvando a mejorar la eficiencia y eficacia del Hospital.

Este documento está estructurado bajo un esquema general determinado por el nivel Central de la Universidad. El capítulo 1 presenta la Introducción, justificación y objetivos. El capítulo 2 se refiere a los antecedentes investigativos respecto al tema, el capítulo 3 corresponde al marco Metodológico, el capítulo 4 presenta los resultados y discusión y el capítulo 5 engloba conclusiones y recomendaciones.

#### **1.2. JUSTIFICACIÓN**

La globalización ha cambiado la forma de trabajar y comunicarse, así también las relaciones de producción y las modificaciones en la prestación de servicios; la pandemia de COVID-19 también ha constituido un reto en distintos ámbitos, es así que en el ámbito de la salud dejó ver las deficiencias sanitarias y de equipamiento en los hospitales, durante el pico de contagios hubo necesidad de hospitalización de los pacientes, observándose el déficit de personal para atenderlos, la mínima cantidad de camas para albergar pacientes

en UCI y la poca disposición de espacios para atender emergencias, lo que hizo improvisar en muchos aspectos.

Dentro de este contexto, se realizó un estudio en el Hospital General Básico IESS del Puyo sobre la necesidad de camas en un número óptimo, para mejorar la calidad de servicio que brindan a los afiliados. El enfoque en sí está dirigido a pronosticar estadísticamente el número de camas que necesita disponer el Hospital para atender a los pacientes que los requieran en todas las áreas que brinda atención y considerando posibles urgencias que puedan ocurrir, como la suscitada con la pandemia; con ello se estaría brindando una mejor atención, optimización de recursos por traslados a otros centros, y se evitaría inconvenientes porque la atención es completa y oportuna en el mismo centro de salud.

El desarrollo del modelo estadístico es para hacer pronósticos probabilísticos de la utilización de las camas en hospitalización y emergencia, con ello los beneficiarios directos son los afiliados que en determinado instante van a hacer uso de los servicios. Y los beneficiarios indirectos corresponde a las personas encargadas del área administrativa del hospital quienes con la aplicación del programa estadístico se va a proyectar el número de camas que el Hospital debe disponer para dar una atención digna a los pacientes lo que evidenciará un manejo administrativo eficaz de los recursos. También forman parte de este grupo los familiares de los pacientes que son atendidos en esa casa de salud, ya que cuentan con la certeza de que, si sus familiares requieren internación, podrán ser atendidos en la misma casa de salud sin tener que preocuparse por buscar opciones para ser derivados a otros centros asistenciales.

### **1.3. OBJETIVOS**

#### **1.3.1. Objetivo general**

Plantear un modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS

#### **1.3.2. Objetivos Específicos:**

- Caracterizar modelos estadísticos que consoliden el modelo propuesto para pronosticar la ocupación de camas del hospital objeto de estudio.

- Construir un modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS basado en las características de la cartera de servicios del hospital y su potencial población de usuarios.
- Simular el modelo estadístico prospectivo propuesto para obtener una alternativa de solución adecuada.
- Determinar la eficacia del modelo estadístico, de acuerdo a los resultados obtenidos al ejecutar el programa

## CAPÍTULO II

### ANTECEDENTES INVESTIGATIVOS

#### 2.1. ESTADO DEL ARTE

Tomando en consideración los objetivos de este trabajo de investigación a continuación se presenta lo más relevante de estudios relacionados que antecedieron a lo que se pretende desarrollar:

Quesada [1] en su investigación titulada “Cantidad, Uso y Gestión de las Camas Hospitalarias. Tendencias en el mundo y situación en Mendoza”, describe como objetivo ajustar la cantidad de camas que se necesita en el hospital para el cuidado oportuno de la población de Mendoza. En este trabajo hace un análisis sobre la necesidad de camas e indica que la cantidad de camas hospitalarias que se necesitan no hay como especificar generalmente porque ello no solo obedece a la eficacia en la parte administrativa, sino también obedece al impulso de otros departamentos de atención al público y de la incorporación de tecnologías digitales que intervienen en su campo para determinar situaciones de utilización. Examina principalmente la correspondencia entre la cantidad de camas y la estancia media (EM), obteniendo como resultados que si se resuelve aumentar el número de camas para atención se debería tener en cuenta el sitio donde van a ser ubicadas y el servicio que van a prestar, o determinar que no es necesario construir camas y solo hay que hacer rendir de forma óptima las camas disponibles.

Ceballos, Velázquez & Posada [2] en su trabajo “Duración de la estancia hospitalaria. Metodologías para su intervención”, se planteó como objetivo enumerar las causas más comunes encontradas en la prolongación de la estancia y las metodologías de logística hospitalaria más aplicadas para su estudio y mejoramiento. Presenta como resultados que los factores causales de estancias prolongadas más encontrados en la literatura son: demora en la realización de procedimientos quirúrgicos y diagnósticos, necesidad de atención en otro nivel de complejidad, situación socio familiar y edad del paciente. Se concluye que para analizar el problema de la estancia hospitalaria es conveniente realizar un “ajuste por riesgo”, utilizando el método de grupo relacionado de diagnóstico (grd) y

que una metodología adecuada es la simulación, para la identificación de cuellos de botella.

Barado [3] en su trabajo cuyo tema es “Propuesta metodológica para la elaboración de Modelos de Simulación de la ocupación de las camas de una Unidad de Cuidados Intensivos”, el objetivo propuesto fue el de pronosticar cuáles van a ser las necesidades de camas o el número de enfermos que no van a poder ser hospitalizados por falta de cama. Este trabajo presenta una metodología basada en el desarrollo de un modelo de simulación con los pacientes ingresados durante un periodo de nueve años en la Unidad de Cuidados Intensivos (UCI), considerando las variables fechas de ingreso y alta, escalas de gravedad, complicaciones infecciosas durante la estancia y desenlace final del paciente. Obteniéndose resultados inéditos sobre la influencia de las decisiones médicas en el funcionamiento de una Unidad de Cuidados Intensivos, con este estudio se logró optimizar los parámetros de funcionamiento de una UCI y se realizó la modificación de la duración de la estancia en la sala de UCI de los pacientes.

Capistran M. Capella, A. Christen, J. [4] en su investigación sobre “Modelos matemáticos predictivos y pronósticos de demanda de camas hospitalarias por epidemia de COVID-19”, se plantearon como objetivo hacer predicciones o inferencias científicamente sólidas de una realidad física que permitan tomar decisiones informadas. Metodológicamente, se asumió el modelo ama-1 para pronosticar la demanda hospitalaria que se compone de tres elementos fundamentales: 1) un modelo dinámico compartimental de tipo susceptible, expuesto, infectado, recuperado y deceso (SEIRD), como los que típicamente se emplean en epidemiología; 2) la elección de parámetros postulados e inferidos, y 3) un modelo de inferencia bayesiana. Con el modelo desarrollado se puso en claro cómo la epidemia afecta a México según la región y la velocidad de contagio; además se ha aprendido que en casi todos los países del mundo hay una segunda tasa de ataque de la enfermedad debido a los pacientes ambulatorios.

Fundación DESQBRE [5] en un artículo informativo denominado “Crean un Modelo Predictivo de ocupación de camas en las Unidades de Cuidado Intensivo en los hospitales de Andalucía”, destaca como objetivo apoyar con la especificación de medidas preventivas, tales como la instauración de hospitales ambulatorios o la concesión de instrumentos y materiales hospitalarios, para enfrentar posibles rebrotes de pacientes infectados por COVID-19. La opción matemática fue diseñar un instrumento que está

fundamentado en la simulación de eventos discretos, que encaminan a un pronóstico de posibles ingresos de pacientes a hospitalización. Para ejecutar estas predicciones se utiliza un modelo matemático que considera las distribuciones de tiempos de permanencia de los pacientes hospitalizados en la Unidad de Cuidados Intensivos, simultáneamente con la cantidad de pacientes que requieren de UCI. Como conclusión del trabajo indicó que las matemáticas aplicadas y la estadística jugaron un papel importante para establecer estrategias y pronosticar la conducta a futuro de la epidemia, proveyendo procedimientos logísticos que mejoren el uso de los recursos aprovechables.

Centro Cochrane Iberoamericano [6] en el trabajo investigativo bajo el nombre “¿Qué prometen los modelos matemáticos para evaluar la insuficiencia de camas para hospitalización y tratamiento de COVID-19 en las Unidades de Cuidados Intensivos?” asemeja y detalla brevemente los modelos matemáticos planteados en la investigación, los cuales permiten prever la necesidad de camas para hospitalización de pacientes y/o para la estancia de enfermos en la Unidad de Cuidados Intensivos debido a la COVID-19. Para la metodología incluyen modelos matemáticos cuantitativos, conceptuados como un estudio matemático que presenta las variables y sus interrelaciones para explicar los fenómenos observados o anunciar hechos futuros que son generalmente aplicados para disponer las medidas en salud. Los resultados emitidos permiten determinar la fracción fija de pacientes que necesitan hospitalización y cuidados críticos (UCI), se identifica también al número previsto de casos de COVID-19 que tienen necesidad de hospitalización o ingreso a UCI.

Mallor [7] en su investigación denominada “Modelo matemático para predecir el número de camas que en la Unidad de Cuidados Intensivos se necesitará durante cada oleada de COVID-19” se planteó como objetivo fundamentar que los modelos matemáticos asienten relatar sobre lo sucedido durante la pandemia y respecto al estado real de la pandemia, además de proporcionar pronósticos importantes sobre la evolución de la pandemia posteriormente. En la parte metodológica empleada da a conocer que los modelos matemáticos de simulación son ventajosos para predecir variables concernientes con el progreso de la pandemia clasificando a las personas en conjuntos que representan su estado en correspondencia con la enfermedad. Para emitir resultados utiliza probabilidades “p”, curvas de crecimiento poblacional de tipo Gompertz, cuya derivada se muestra en una distribución de probabilidad de Poisson. Del análisis estadístico pronosticado para miles de casos resultan los vaticinios medios y bandas de confianza

que permiten pronosticar el número de camas que van a ser necesarias a futuro mientras siga la pandemia.

Cabanilla [8] en su trabajo de investigación denominado “Diseño de un modelo administrativo para optimizar la gestión de camas en los hospitales públicos de la ciudad de Machala” presenta como objetivo de la investigación: optimizar la gestión de camas para el hospital diseñando un modelo administrativo basado en las leyes vigentes que dictamina el Sistema Nacional de Salud en el Ecuador. Se estudiaron los dos hospitales públicos existentes en Machala, operativamente pertenecientes el uno al Ministerio de Salud Pública y el otro al Instituto Ecuatoriano de Seguridad Social, para confrontar en términos de eficiencia de la administración de las camas de los hospitales. Utilizando para ello una metodología descriptiva y de observación a través de la cual se determinó la cantidad de cirugías que se realizan en cada nosocomio, así también se verificó la cantidad de suspensiones de atención por la falta de camas disponibles para la hospitalización de pacientes y como incurre en la percepción del nivel de satisfacción de los usuarios del hospital. Como resultados presenta que la administración de la ocupación de camas está afectado, entre otros elementos por la demanda de los servicios hospitalarios y la sobredemanda de población que desea ser atendida esos bloques médicos y concluye que los hospitales públicos demandan el perfeccionamiento del trabajo administrativo para la gestión de dotar camas para el hospital, y se termina convirtiendo en una prioridad, por tal razón, se estipula que debe ser considerada la aplicación de éste modelo matemático para gestionar camas hospitalarias.

Morera [9] en el trabajo de investigación realizado cuyo nombre es “Gestión de estancias y ocupación de camas de hospitales públicos de Costa Rica.”, tuvo como objetivo determinar si la variación de los niveles de ocupación de camas es producto de una planificación deficiente del uso de las camas en hospitalización en función de la demanda, o si se trata de una inadecuada dirección de la permanencia de los pacientes. La investigación que se detalla fue realizada en el año 2011 en la Caja Costarricense de Seguro Social. Utilizando gráficos de dispersión se comprueban el índice de funcionamiento que mide la eficiencia en el manejo de las estancias. Los resultados presentados son que el 58% de los hospitales muestra deficiente distribución interna de las camas, lo que ocasiona que ciertos servicios estén tengan sobre demanda y otros registren índices muy bajos con respecto al nivel óptimo. El 83% de los hospitales

públicos poseen más de un servicio con estancias mayores a lo esperado, de acuerdo con los casos que atienden. Como conclusión del estudio indica que la mayoría de los hospitales presentan una incorrecta distribución interna de las camas hospitalarias, escenario que se podría corregir fijando el número de camas según la demanda deseable en cada especialidad, esto hace necesario realizar un análisis más minucioso del manejo de estancias de los principales grupos que corresponde a diagnóstico y la elaboración de protocolos para equilibrar la asistencia de servicios de salud en los pacientes pertenecientes a situación de diagnóstico con mayor predisposición a situarse en estancia media.

González & Hernández [10] realizaron una investigación cuyo tema fue “Indicadores de gestión hospitalaria” donde se abordó asuntos sobre los indicadores de gestión hospitalaria desde la implementación efectiva de nuevas decisiones por parte de gerencia considerando el examen de los indicadores especificados y planteados en tres hospitales de Maracaibo, Venezuela, durante el periodo 1996-2002; el acercamiento al objeto de estudio se empezó con una investigación exploratoria y una investigación bibliográfica y para posteriormente culminar con una investigación empírica, aplicando un esfuerzo de observación participante, a través de pasantías profesionales. Se demostró, que en los hospitales investigados se calculan indicadores concernientes a su capacidad, productividad y eficiencia; sin embargo, no se verificó una relación aparente entre las decisiones emanadas desde gerencia y la información que de ellos se extrae.

## **2.2. FUNDAMENTACIÓN TEÓRICA**

Para lograr construir un modelo estadístico que permita analizar, exponer, representar y predecir satisfactoriamente el número de camas requerido en el Hospital IESS de Puyo, fue preciso incursionar en la investigación bibliográfica que se presenta en el siguiente apartado.

### **2.2.1. Modelos Estadísticos.**

En la actualidad se reconoce la jerarquía de la Estadística Aplicada en el avance de trabajos de investigación en diversos campos de estudio; día tras día aumenta el número de profesionales de distintas disciplinas que demandan de métodos estadísticos como simulación, muestreo, diseño de experimentos, modelamiento estadístico e inferencia,

para realizar la respectiva recolección de datos, la organización y el análisis de datos y para su ulterior interpretación. [11]

Con estas aseveraciones del autor, cabe recalcar que la Estadística está presente en todos los campos de investigación, en el área administrativa, de educación, entre otros.

Un modelo estadístico es una descripción matemática de las conexiones que existen entre las variables en estudio. Es una descripción de la realidad, por tanto, nunca son correctos o incorrectos, pero pueden ser útiles. Cabe indicar que los modelos estadísticos, son llamados también modelos estocásticos. [12]

“Un modelo es una forma de simulacro de un procedimiento real, con el que se procura comprender un hecho mediante predicciones que permitan ayudar a mejorar su rol o controlar para que así suceda. En esta perspectiva, los modelos matemáticos pueden ser físicos, explicados por variables medibles y equivalentes representados en diagramas de flujo” y simbólicos ya sea en presentación matemáticos, lingüísticos o esquemáticos. [11]

Los modelos matemáticos llamados también cuantitativos son explicados a través de una serie de símbolos y relaciones lógico–matemáticas.

Para diseñar un correcto modelo matemático es razonable apoyarse en leyes que representen la conducta del sistema. También cuenta mucho todo lo referente con la experiencia de ejecutar los programas, además la imaginación, la intuición, la habilidad y la simplicidad son muy importantes para elegir el conjunto más pequeño de variables.

En primera instancia hay que instituir el problema en forma clara, precisa y lógica delimitando sus contornos, luego se efectúa la recolección y depuración de datos, seguidamente se hace la diagramación del experimento, luego se efectúa las pruebas de contraste para proseguir a la comprobación de funcionamiento del modelo y por último realizar la comprobación de la hipótesis planteada. Cabe resaltar que el modelo matemático o estadístico debe tener una gran similitud con el sistema actual, también debe aglutinar los aspectos reveladores del sistema y por supuesto debe implicar un manejo fácil cuyas respuestas sean comprensibles. Un aspecto fundamental es que exista una excelente correlación entre lo que manifiesta el modelo programado y lo que el sistema real emana actualmente.

En la vida real la recolección de datos no siempre tiene acceso a toda la información por lo que un modelo estadístico ayuda a inferir los resultados, ese procedimiento de inferencia se llama ajuste de modelo, aunque a veces el modelamiento no es exitoso o difícil de aplicar.

También vale aclarar que un modelo estadístico es un tipo de modelo matemático que utiliza probabilidades para obtener resultados y está especificado por ecuaciones que relacionan las variables aleatorias, aunque también pueden aparecer otras variables no aleatorias. Los principales modelos estadísticos se describen a continuación: [11]

- a) Modelos determinísticos: son aquellos en los cuales los resultados son muy predecibles y no hay aleatoriedad; es decir, se tiene certeza de los valores de los parámetros.

Esta dada por la ecuación:  $y_i = a + bx_i$

- b) Modelos estocásticos: se denominan así cuando el enfoque es más en los modelos que en los datos; sin embargo, las variables se predicen con cierta variación o incertidumbre en base a comportamientos estimados. Un proceso estocástico es una colección o familia de variables aleatorias que ayudan a explicar la realidad y probar la hipótesis planteada. La ecuación que se ajusta a un tipo de este modelo es:

$$y_i = a + bx_i + \varepsilon_i$$

Además de los dos modelos señalados, están los modelos de series de tiempo que habitualmente se utilizan para referir procesos que son muestreados en puntos de tiempo discretos, mientras que procesos precisos se utilizan para modelar fenómenos que están presentes de forma irregular, sin un modelo estacional, que pueden ocurrir en cualquier instante o punto.

Por otra parte, y equivalente al proceso de experimentación que se realiza en laboratorios con el objetivo de acrecentar la comprensión de cierta teoría y para certificar el uso del modelo a posterior, es preciso efectuar la simulación, la cual es considerada como un método de prueba controlado. Cabe señalar que es un asunto de imitación de talentos importantes del proceder de un sistema, con la construcción de un modelo realizado en una computadora, hecho para que permita formar observaciones proporcionadas ciertas entradas. [11]

### 2.2.1.1.Sistemas

Definiendo a un sistema se puede decir que es una fuente de datos de la conducta de cualquier situación que ocurre en cierta parte del mundo. Está conformado por elementos que intervienen simultáneamente para alcanzar el objetivo planteado.

Es importante señalar que los sistemas suelen poseer algunos parámetros, atributos y variables, que adoptan valores numéricos lógicos, es así que “un sistema podría ser adaptativo o no adaptativo, estable o inestable, natural o artificial, dinámico o estático, lineal o no lineal; así también puede tener variables independientes o dependientes, no controlables o controlables, continuas, discretas o mixtas, no observables u observables”. En un sistema se producen interacciones entre los elementos que lo componen, todo esto se explican en reglas que establecen la forma en la que las variables que intervienen se transforman con el tiempo. Se conoce como variables de estado a aquellas que puntualizan las formas, las actividades y los atributos presentes en un instante específico del sistema, además permiten anunciar su conducta a futuro y sus valores proporcionan datos del sistema en ese instante, además el sistema relaciona situaciones del pasado con el futuro a través de hechos del presente. [11]

Ahora bien, si en el sistema puede predecirse la conducta de los elementos con mucha seguridad, se denomina sistema determinístico, si esto no ocurre se denomina sistema estocástico. En este contexto, si la probabilidad de encontrarse en alguno de los estados no cambia con el tiempo se denomina sistema estático, caso contrario pasa a ser un sistema dinámico. Así también cuando el estado cambia sólo en ciertos momentos con el tiempo, entonces se trata de un sistema discreto, de lo contrario de un sistema continuo. [11]

### 2.2.1.2.Relación entre sistemas y modelos

Para una mejor comprensión, se explica a través de un ejemplo supuesto. La explicación se realiza a través de una función que conjuga a un conjunto de datos ( $d$ ) que representa a las variables de respuesta versus un grupo de parámetros  $P(m_1, m_2..)$ ; cada conjunto de datos específicos de este grupo de parámetros suministra un modelo ( $m$ ) contrario. Así también, si se tiene un modelo físico ( $G$ ), producido a partir de la teoría, que relaciona los datos observados con los parámetros conocidos; es decir las variables, se alcanza una relación práctica  $G \Rightarrow F(d, m)$  que describe el fenómeno; si esta relación es lineal, se especifica entonces como  $Gm = d$ . Con esto, se pueden obtener dos situaciones distintas

que se detallan a continuación: se puede conocer los parámetros del modelo, pero es imperioso saber la respuesta que emite el sistema, este escenario es reconocido como el problema directo; en caso contrario donde se dispone de observaciones de las variables de predicción y de respuesta, pero se desconocen los parámetros del modelo que expliquen sobremanera la relación entre esas variables, entonces se dice que es el problema inverso, el mismo que se resuelve con regresión estadística. Ahora, para satisfacer el problema inverso es necesario estimar los valores del modelo ( $m$ ) que expongan mejor las observaciones. [11]

#### 2.2.1.3. Validación de modelos y evaluación de resultados

Una vez conocidos los valores necesarios hay que efectuar una validación del modelo. Se debe cuantificar qué tan apropiadamente el modelo refiere los datos, las simulaciones u observaciones para los cuales fue aplicado y cómo está el ajuste de los valores. Antes de valorar el modelo matemático obtenido es imperioso revisar la enunciación del problema con la finalidad de descubrir posibles errores y poder establecer así la consistencia de las expresiones matemáticas.

Consecutivamente la otra etapa se fundamenta en valorar el estadístico de prueba denominado coeficiente de correlación y verificar los resultados de una prueba F; un análisis de varianza y otros análisis pertinentes que sean de gran utilidad según el modelo que se esté aplicando. En la evaluación de resultados se pueden reformar los parámetros de entrada y verificar la conducta de valores obtenidos y comparar con los datos históricos para modificar valores de los resultados del nuevo modelo. [11]

En definitiva, es necesario comparar los resultados y verificar si las condiciones o supuestos anteriores coinciden con los alcanzados en los resultados evidenciados con el nuevo modelo matemático, para ello es necesario la aplicación de pruebas de bondad de ajuste de datos. Cabe mencionar que existen factores significativos que se deben considerar en esta etapa; los resultados logrados ordinariamente como producto del vínculo entre los factores de trabajo, tiempo y dinero. En este contexto es sustancial conseguir la mayor cantidad de información y dar a conocer en resumen los resultados que son de beneficio para los usuarios indicando que los valores obtenidos son la derivación de un trabajo consciente y consecuente que merece un análisis objetivo que se acerque a lo real. [11]

#### 2.2.1.4. Pruebas para la certificación del modelo

Con la instauración de un modelo matemático se alcanzan dos diferentes fuentes de variación, la primera debida a la regresión (*SCR*) y la segunda correspondiente al error (*SCE*), en consecuencia, la variación total (*SCT*) corresponde a la suma de estas dos fuentes de variación. La consabida variación se estipula de la siguiente forma:

$$SCR = m'G'd - \frac{(\sum d_i)^2}{n}$$

$$SCE = d'd - m'G'd$$

$$SCT = d'd - \frac{(\sum d_i)^2}{n}$$

El coeficiente de determinación o llamado también de correlación  $R^2$  mide la proporción de variación total de las observaciones con respecto a su media la cual puede ser atribuida en la recta de regresión estimada.

$$R^2 = \frac{SCR}{SCT} = 1 - \frac{SCE}{SCT}$$

Donde:

*SCT* significa variación total con respecto a la media

*SCR* indica la parte de variación atribuible a un efecto lineal de las variables predictivas sobre las variables de respuesta.

Si  $R^2 = 1$  se puede aseverar que toda la variación en las observaciones es explicada por la presencia de las variables predictivas *G* en la ecuación de regresión. [11]

#### 2.2.2. Proceso estocástico

Se puede empezar anotando que un proceso estocástico está constituido por una familia de variables aleatorias, denotada por:  $Y_t, t \in T$  definidas por un espacio muestral  $\Omega$  y que  $\sigma Y(t)$  toman valores en un conjunto *E* (puede ser  $\mathbb{R}$ , pero también pueden ser  $C, R^k$  o  $C^k$  *T* es el espacio de tiempos; por lo general es  $\mathbb{R}$  o un subconjunto de este, puede ser  $\mathbb{Z}$  o  $\mathbb{N}$ ).

Se adjudica que  $T = \mathbb{Z}$ : conjunto de números enteros y que el proceso es real porque toma valores en  $\mathbb{R}$ ). Mientras no se establezca lo contrario. [13]

El proceso estocástico es considerado como un modelo matemático que describe a lo largo del tiempo la estructura de probabilidad de una serie de observaciones. Es así que una serie de tiempo  $Y(t)$  se considera como la ejecución de un proceso estocástico que se plantea solo para un número finito de períodos, indexado por  $t=1, \dots, n$

Su representación algebraica es:  $\{Y(t)\}_t^{\infty} = -\infty$

En términos generales, se dice que un proceso estocástico es estacionario si su media y su varianza son valores constantes en el tiempo y si el dato de la covarianza entre dos periodos obedece sólo al trayecto o rezago entre estos dos periodos, y no al tiempo en el que se calculó la covarianza. [13]

### 2.2.3. Series de tiempo

El tema del análisis de las series de tiempo es muy amplio y siempre está en evolución; algunas de las diversas técnicas del análisis de las series de tiempo son muy complejas; sin embargo, resultan efectivas cuando se necesita conocer pronósticos de ocurrencia de un evento. [13]

#### 2.2.3.1. Componentes de una serie de tiempo

“Los modelos de regresión que consideran series de tiempo son muy comunes para los pronósticos.” Para realizar un análisis empírico las series de tiempo generalmente se consideran como estacionarias; sin embargo, puede darse el caso que las series de tiempo no son estacionarias, entonces la regresión resulta fraudulenta.

Para saber si un pronóstico es válido o no, sean o no las series de tiempo estacionarias sobre las cuales se basa el estudio deben efectuarse antes las pruebas para la estacionariedad que las de causalidad. [14]

#### *Ruido blanco.*

Un tipo especial de proceso estocástico (o de series de tiempo): el proceso puramente aleatorio o de ruido blanco. Se dice que un proceso es puramente aleatorio si tiene una media igual a cero, una varianza constante  $\sigma^2$  y no está seriamente correlacionado. [13]

Una serie  $w_t, t \in \mathbb{Z}$  se dice que cuando es Ruido Blanco sucede lo siguiente:

$$E(w_t)=0 \text{ (media cero)}$$

$$\text{Var}(w_t)=\sigma^2 \text{ (varianza constante)}$$

$$\forall k \neq 0, \text{Cov}(w_t, w_{t+k}) = 0 \text{ (sin correlación)}$$

Si conjuntamente cumple que  $w_t \sim \mathcal{N}(0, \sigma^2)$  se dice que  $w_t$  es Ruido Blanco Gaussiano (RBG). [12]

### *Tendencia.*

Se designa tendencia de una serie temporal a su comportamiento o movimiento de los datos en un largo plazo, la línea recta graficada podría representar la tendencia creciente o decreciente.

Para calcular la tendencia. Usaremos la siguiente expresión:

$$T_t, t = 1, \dots, n \quad \text{o bien} \quad T_{j,k}, i = 1, \dots, n, k = 1, \dots, m \quad [15]$$

### *Ciclos.*

Normalmente, los ciclos suelen afectar menos a nuestras vidas que la estacionalidad. También se ha especulado mucho sobre la existencia de ciclos que se repiten cada cierto período de tiempo en la economía y que podrían influir mucho en nuestras vidas.

Esta componente refleja comportamientos recurrentes, aunque no tienen por qué ser exactamente periódicos, con un periodo superior a un año. Muestran, habitualmente, cómo se suceden las etapas de bonanza económica con las de crisis, o al menos, desaceleración.

No hay que separar ciclo y tendencia por lo que, siempre que nos refiramos a la tendencia, estaremos hablando, de hecho, de la ciclo-tendencia. [14 ]

### *Estacionalidad.*

La estacionalidad es la repetición de determinadas variaciones en alguna variable cada cierto período, normalmente igual o menor a un año. En períodos más amplios se suele hablar de ciclos, aunque las variaciones cíclicas no son tan frecuentes como las estacionales

La estacionalidad generalmente hace que la serie no sea estacionaria porque los valores promedio en algunos momentos particulares dentro del intervalo estacional (meses, por ejemplo) pueden ser diferentes de los valores promedio en otros momentos.

### *Estacionariedad.*

Intuitivamente el concepto se refiere a que las propiedades de la serie no varían con respecto al tiempo. En otras palabras, significa que su variación no cambia en función del tiempo. Esto tiene una importante implicación a la hora de predecir, puesto que, de tener estacionariedad, se estaría prediciendo que las características estadísticas de nuestra serie de tiempo serán las mismas en el futuro como en el pasado.

Otra consecuencia importante es que “estacionarizando” una serie de tiempo se puede obtener información significativa como media, varianza y autocorrelaciones (correlaciones entre distintos valores de la serie de tiempo); dichos valores son útiles para describir el comportamiento futuro únicamente si la serie es estacionaria.

Si hay presencia de tendencia positiva, la media y varianza muestral aumentarán y se subestimarán a la media y varianza en periodos posteriores. Y si la media y varianza no están bien definidas, tampoco lo estarán las autocorrelaciones. Por ende, cuando se trabaja con series de tiempo no es recomendable ajustar una regresión, pues los datos no son estáticos (estacionarios). [14]

Verificar esta propiedad en el estudio de las series de tiempo tiene su importancia en los siguientes aspectos.

*Facilidad de Análisis:* Entre todos los procesos estocásticos, los procesos estacionarios resultan ser un caso particular mucho más fácil de analizar.

*Mejor Entendimiento:* Permite modelar fenómenos de mayor complejidad, la estacionariedad es un supuesto común a la hora de realizar estimación de tendencia, previsión financiera (forecasting), inferencia, entre otros.

*Ubicuidad:* Es decir la presencia de la estacionariedad no sólo en el problema que estemos analizando, sino en el campo de estudio que abarca. [16]

Un proceso estocástico o aleatorio es una colección de variables aleatorias ordenadas en el tiempo. Un tipo de proceso estocástico que ha recibido gran atención y ha sido objeto de escrutinio por parte de los analistas de series de tiempo es el proceso estocástico estacionario.

En términos generales, se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende sólo de la distancia o rezago entre estos dos periodos, y no del tiempo en el cual se calculó la covarianza

Una serie de tiempo es estrictamente estacionaria si todos los momentos de su distribución de probabilidad, y no sólo los dos primeros (es decir, la media y la varianza), son invariantes respecto del tiempo. Sin embargo, si el proceso estacionario es normal, el proceso estocástico débilmente estacionario también es estrictamente estacionario, pues el proceso estocástico normal está del todo especificado por sus dos momentos, la media y la varianza. [14]

#### 2.2.3.2. Modelos ARIMA

Los pronósticos son una parte importante del análisis econométrico, los enfoques de los pronósticos económicos basados en series de tiempo son cinco, por la naturaleza de esta investigación se describirá el autorregresivo integrado de promedios móviles ARIMA conocido como metodología de Box-Jenkins y el modelo SARIMA

El modelo ARIMA constituye una nueva generación de herramientas de pronóstico. popularmente conocida como metodología de Box-Jenkins (BJ), pero técnicamente conocida como metodología ARIMA, el interés de estos métodos de pronósticos no está en la construcción de modelos uniecuacionales o de ecuaciones simultáneas, sino en el análisis de las propiedades probabilísticas, o estocásticas, de las series de tiempo económicas por sí mismas según la filosofía de que los datos hablen por sí mismos. [13] A diferencia de los modelos de regresión, en los cuales  $Y(t)$  se explica por las  $k$  regresoras  $X_1, X_2, X_3, \dots, X_k$ , en los modelos de series de tiempo del tipo BJ,  $Y(t)$  se explica por valores pasados o rezagados de sí misma y por los términos de error estocásticos. Por esta razón, los modelos ARIMA reciben algunas veces el nombre de modelos *ateóricos* — porque no se derivan de teoría económica alguna—, y las teorías económicas a menudo son la base de los modelos de ecuaciones simultáneas.

Generalmente en los modelos ARIMA se trabaja con una sola serie de tiempo. No obstante, el análisis puede extenderse a modelos ARIMA multivariados. [14]

### 2.2.3.3. Modelos SARIMA

Es un modelo ARIMA estacional, son modelos que captan el comportamiento puramente estacional de una serie, puede decirse que es una serie con influencia en su componente estacional que se denomina modelo SARIMA (P.D.Q) [17]

El modelo ARIMA estacional (SARIMA) concentra factores estacionales y no estacionales en un modelo multiplicativo. Una anotación sintetizada para el modelo es ARIMA (p.d.q)× (P.D.Q)<sub>s</sub> 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

S=ventana de tiempo del patrón estacional

Anulando las operaciones de diferenciación, el modelo se presenta de la siguiente forma:

$$\Phi(B^S)\phi(B)(X_t - \mu) = \Theta(B^S)\theta(B)W_t$$

Los componentes no estacionales son:

$$AR: \Phi(B) = 1 - \Phi_1 B - \dots - \Phi_p B^p$$

$$MA: \Phi(B) = 1 + \Phi_1 B + \dots + \Phi_q B^q$$

Los componentes estacionales son:

$$AR \text{ estacional: } \Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_p B^{ps}$$

$$MA \text{ estacional: } \Phi(B^s) = 1 + \Phi_1 B^s + \dots + \Phi_q B^{qs} \quad [13]$$

#### 2.2.3.4. Metodología Box-Jenkins

Se describe como una metodología que concentra a un modelo matemático hecho para realizar pronósticos de rangos de datos apoyados en entradas de series de tiempo correctamente determinadas. Así con modelos como éste se consigue analizar un sinnúmero de tipos de datos basados en series de tiempo que poseen desenlaces de predicción, porque constituye una metodología de pronóstico que para el efecto trabaja realizando regresiones de los datos obtenidos mediante series de tiempo.

Así también conviene destacar que esta metodología se fundamenta en el supuesto que los eventos futuros están influenciados por los eventos del pasado, y es más plausible utilizarlo para realizar pronósticos cuyos plazos están entre los rangos de 18 meses o menos.

La metodología de Box-Jenkins advierte datos manejando tres principios que son: autonomía, diferenciación y promedio de movimiento. Estos principios se simbolizan con las letras p, d y q, respectivamente al principio enunciado, se muestran juntos con el nombre de ARIMA (p, d, q). [18]

A continuación, se da a conocer los pasos que sigue esta metodología.

*Paso 1. Identificación.* Es decir, encontrar los valores apropiados de  $p$ ,  $d$  y  $q$ . En este paso el correlograma y el correlograma parcial ayudan en esta labor.

*Paso 2. Estimación.* Tras identificar los valores apropiados de  $p$  y  $q$ , la siguiente etapa es estimar los parámetros de los términos auto-regresivos y de promedios móviles comprendidos en el modelo. Algunas ocasiones, los cálculos se realizan con mínimos cuadrados simples, y otras veces es preciso acudir a métodos de estimación no lineal (en parámetros) para su obtención.

*Paso 3. Examen de diagnóstico.* A continuación de seleccionar un modelo ARIMA exclusivo y de considerar sus parámetros, se procede a ver si el modelo seleccionado se concierta a los datos en forma razonable, ya que es posible que exista otro modelo

ARIMA que también cumpla con los parámetros. Es por esto por lo que el diseño de modelos ARIMA de Box-Jenkins es un arte más que una ciencia; puesto que para seleccionar el modelo ARIMA adecuado se requiere mucha experiencia al escoger según los parámetros designados. Una breve prueba para ver si el modelo escogido es el correcto, es determinar si los residuales estimados con este modelo matemático son de ruido blanco; si es así, se acepta el ajuste particular; si no lo es, hay que empezar de nuevo. Por tanto, la metodología BJ es un proceso iterativo.

*Paso 4. Pronóstico.* - Una razón de la popularidad del proceso de construcción de modelos ARIMA es su éxito en el pronóstico es porque los pronósticos obtenidos por este método son más confiables que los obtenidos de modelos econométricos tradicionales, en particular en el caso de pronósticos de corto plazo, por supuesto, cada caso debe verificarse. [14]

Los métodos Box-Jenkins y VAR para pronósticos económicos son opciones respecto de los modelos tradicionales uniecuacionales y de ecuaciones simultáneas.[14]

Para pronosticar valores de una serie de tiempo, la estrategia básica de Box-Jenkins es la siguiente:

- a) Examine primero si la serie es estacionaria. Esto se logra al calcular la función de auto-correlación (FAC) y la función de auto-correlación parcial (FACP), o mediante un análisis formal de raíz unitaria. Los correlogramas asociados a FAC y FACP son, con frecuencia, buenas herramientas de diagnóstico visual.
- b) Si la serie de tiempo es no estacionaria, debe diferenciarse una o más veces para alcanzar la estacionariedad.
- c) Se calculan entonces la FAC y la FACP de la serie de tiempo estacionaria para determinar si la serie es autorregresiva pura, del tipo de promedios móviles puro, o una mezcla de las dos.
- d) Se estima el modelo tentativo.
- e) Se examinan los residuos de este modelo tentativo para establecer si son de ruido blanco. Si lo son, el modelo tentativo es quizás una buena aproximación al proceso estocástico subyacente; si no lo son, el proceso se inicia de nuevo, volviendo al método de Box-Jenkins iterativo.
- f) El modelo finalmente seleccionado sirve para pronosticar. [14]

## **2.2.4. Hospital IESS Puyo**

### **2.2.4.1. Reseña histórica del Hospital IESS Puyo**

De acuerdo con los archivos que reposan en el hospital, la atención por parte del IESS en esta provincia se inició en 1965, con 2 horas de consulta médica diarias; en 1968 se inaugura el primer Dispensario Médico del Seguro Social, en un local cedido por el Vicariato Apostólico de Puyo.

Transcurrido el tiempo, el espacio físico que dispone el hospital cada vez ha ido quedando reducido, ya sea por el incremento de afiliados como por el incremento de especialistas.

Hoy en día, el Hospital Básico El Puyo tiene un nivel de atención Tipo II de tipología II-4 del Sistema Nacional de Salud; brinda atención de consulta externa con las Especialidades de Pediatría, Medicina Interna, Ginecología, Cirugía General, Traumatología, Salud Ocupacional, Psicología, Dermatología, Cardiología, Otorrinolaringología, Fisiatría, Urología y Gastroenterología, además de Medicina General, Medicina Familiar y Preventiva, con atención mediante visita domiciliaria y Nutrición y Dietética. También cuenta con el servicio de Odontología, con las especialidades de Endodoncia Odontológica, Odontopediatría y Cirugía Dento-Alveolar.

Dispone también de servicios de apoyo en diagnóstico como: Laboratorio Clínico e Imagen (Rayos X, Ecografías, Densitometrías y Mamografías); servicios complementarios de: Fisioterapia, Rehabilitación, Estimulación Temprana, Terapia de Lenguaje, Ambulancia, Farmacia, Servicio de Emergencia las 24 horas. El hospital brinda su atención a la población de los cuatro cantones de la Provincia, así como a los beneficiarios de IESS de las Provincias cercanas. [19]

En concordancia con lo antes manifestado se determina que la cobertura geográfica que atiende el hospital es muy amplia; por lo tanto, el número de personas que atiende también es grande y a veces la atención tarda demasiado.

### **2.2.4.2. Incidencia de la pandemia en el Hospital IESS de Puyo**

Durante la pandemia del COVID-19, la necesidad de atención en consulta externa y en emergencia creció notablemente, agudizando el problema de atención, y peor aún la disponibilidad de camas para atender a los pacientes hospitalizados fue escasa; improvisándose sitios de acogida en corredores y pasillos. La necesidad de mayor número

de camas en la Unidad de Cuidados Intensivos (UCI) fue evidente, por lo que se emitieron permisos de traslados a hospitales cercanos, porque no existían camas suficientes para recibirlos, ni el personal propiamente preparado para atender a este tipo de pacientes. En la actualidad el requerimiento de camas es mayor que la cantidad de camas que dispone el hospital, razón por la cual es necesario que las autoridades del hospital traten de cambiar la situación actual.

Al constituirse el hospital del IESS de Puyo una entidad que acoge gran número de pacientes es preciso que se gestione administrativamente el mejoramiento de la atención de los afiliados. En esta última etapa de pandemia por COVID-19 que afectó a nivel mundial, se ha verificado falencias en la disponibilidad de camas en las diferentes secciones del hospital donde se necesitan atender a los pacientes.

Por lo antes expuesto, en este trabajo investigativo se desarrollará un modelo estadístico para que sustente en forma técnica y con un grado de precisión aceptable el número de camas que debe tener a disposición el hospital, para que no incurra en gastos innecesarios o, a la vez, entre en un alto riesgo sus pacientes, por el número insuficiente de camas disponibles para poder atenderlos.

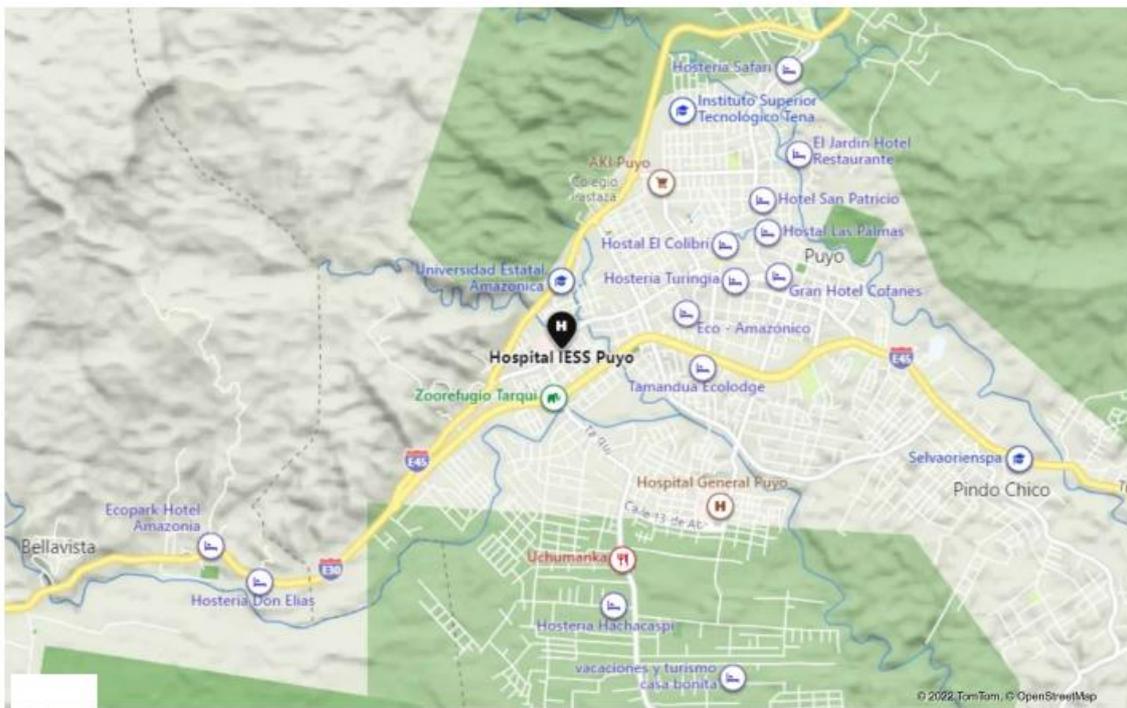
El número de camas hospitalarias que se requiere en un hospital para atender los inconvenientes por las enfermedades que se presentan en la población, es una función que depende, entre otros actores, de la frecuentación (tasa de utilización), los egresos, la estancia media de los pacientes y el porcentaje de ocupación de las camas. [20]

## CAPÍTULO III

### MARCO METODOLÓGICO

#### 3.1. UBICACIÓN

La investigación fue realizada en el Hospital Básico el Puyo, fundado en el año 1981. El Hospital se encuentra ubicado en el Barrio Miraflores, de la ciudad del Puyo, capital de la provincia de Pastaza (figura 1).



**Figura 1:** Hospital Básico IESS Puyo.

Fuente: <https://www.iess.gob.ec/>

A continuación, se detalla la caracterización geográfica y su descripción, así como, la accesibilidad y los límites de la provincia de Pastaza, donde se ubica el Hospital Básico IESS Puyo (IESS, 2021).

### 3.1.1. Caracterización geográfica

Pastaza, es la provincia más grande del Ecuador, pertenece a la Zona 3, cuenta con una extensión del 29.773 km<sup>2</sup> aproximadamente de la zona oriental, equivalente, al 66% de la Región 3 y, el 12%, del territorio nacional. De acuerdo a la división política actual, esta provincia, está conformada por 4 cantones y 21 parroquias, a saber: Pastaza (14 parroquias), Mera (3 parroquias), Santa Clara (2 parroquias) y Arajuno (2 parroquias). [21]

### 3.1.2. Descripción de la ubicación geográfica

En la tabla 1 se presenta la descripción geográfica del Hospital Básico IESS Puyo.

**Tabla 1:** Descripción geográfica del Hospital.

<b>Nombre de la institución</b>		Hospital Básico el Puyo		
<b>Nivel de atención</b>		II-4		
<b>RUC</b>		1660010560001		
<b>Dirección administrativa</b>		Ing. Ruth Procel		
<b>Dirección médica</b>		Dra. Heydi Barroso		
<b>Ubicación</b>	<b>País</b>	Ecuador		
	<b>Provincia</b>	Pastaza		
	<b>Cantón</b>	Pastaza		
	<b>Parroquia</b>	Puyo		
<b>Georreferenciación (utm - wgs84)</b>				
<b>Latitud</b>		-1.4886653	<b>Longitud</b>	-78.0103182
<b>Dirección</b>	<b>Calle principal</b>	Av. Ceslao Marín		
	<b>Calle secundaria</b>	Río Curaray		
	<b>Referencia</b>	Diagonal al MIESS		

Fuente: Ing. Janine Campos, Departamento de Estadística.

### 3.1.3. Accesibilidad

El Hospital cuenta con dos vías de acceso:

- Entrada 1: Av. Ceslao Marín y Río Curaray, acceso directo a la Unidad Antigua.
- Entrada 2: Calle Luis Molina y Diego Celi, acceso al edificio nuevo.

### 3.1.4. Límites

La provincia de Pastaza limita al norte con Napo y Orellana, al Sur con Morona Santiago, al Este con Perú y al Oeste con Tungurahua.

## 3.2. EQUIPOS Y MATERIALES

Los materiales y equipos utilizados dentro de la investigación fueron:

- Materiales
  - Lápices.
  - Esferos.
  - Hojas de papel bond.
  - Libreta.
- Equipos

Hardware:

- HP Laptop 15 -dy2xxx.
- Impresora.
- USB.

Software:

- Microsoft Office 2019.
- Programa R, versión 4.2.1.

## 3.3. TIPO DE INVESTIGACIÓN

En esta investigación se utilizó un enfoque metodológico cuantitativo, con alcance descriptivo, explicativo, longitudinal y proyectivo.

*Investigación Descriptiva:* se encarga de la identificación de las características del evento o fenómeno bajo estudio. Por otra parte, se menciona que esta investigación “busca especificar las propiedades, las características y los perfiles de personas, grupos, comunidades, procesos, objetos o cualquier otro fenómeno que se someta a un análisis”. Este tipo de investigación permitió comprender el comportamiento de las series de tiempo bajo estudio mediante el gráfico de secuencia (o de tiempo) para observar el componente estacional y la tendencia (estacionariedad), así como, los valores extremos. [22] [23]

*Investigación Longitudinal:* permite comparar datos de una población que han sido recolectados en diferentes momentos para visualizar cambios. Para efectos de este estudio, se comparó el porcentaje de ocupación de camas tanto en el área de hospitalización como en emergencias para el período enero 2018 a septiembre 2022. [24]

*Investigación Explicativa:* es aquella que intenta determinar las causas que dan origen a un determinado fenómeno. Esta investigación “se centra en explicar por qué ocurre un fenómeno y en qué condiciones se manifiesta, o por qué se relacionan dos o más variables”. En ese sentido, se busca explicar, para el período enero 2018 – septiembre 2022, cómo ha sido la ocupación de camas en el Hospital Básico IESS Puyo. [23]

*Investigación Proyectiva:* “se asocia a la elaboración de un modelo, plan, o propuesta como solución a un problema detectado por el investigador”; con el fin de predecir el futuro basándose en un análisis previo de un fenómeno de interés; para tomar decisiones y planificar a largo plazo. Por tanto, en este estudio, el modelo obtenido se utilizó para predecir la ocupación de camas en el Hospital Básico IESS Puyo para un período de 12 meses. [25]

### **3.4. PRUEBA DE HIPÓTESIS**

Las hipótesis a contrastar en esta investigación son las siguientes:

$H_0$ : El modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS no es significativo.

$H_1$ : El modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS es significativo.

### **3.5. POBLACIÓN Y MUESTRA**

#### **3.5.1. Población**

La población es el “conjunto total de individuos u objetos con alguna característica que es de interés estudiar”. En esta investigación, la población objeto de estudio está constituida por todos los registros sobre ocupación de camas en las áreas de hospitalización y emergencias que reposan en el Departamento de Estadística del Hospital Básico IESS Puyo. [26]

#### **3.5.2. Muestra**

Se refiere a una parte (subconjunto) de la población. La muestra para esta investigación está conformada por los registros de cinco años sobre ocupación de camas en las áreas de

hospitalización y emergencias, específicamente, para el período enero 2018 a septiembre 2022. [26]

### **3.6. RECOLECCIÓN DE INFORMACIÓN**

Para esta investigación los datos fueron suministrados por el personal del Departamento de Estadística del Hospital Básico IESS Puyo. La información se encuentra registrada en Microsoft Excel, un total de diez (10) archivos, cinco por cada área, hospitalización y emergencias, desde enero de 2018 hasta septiembre de 2022. Cada archivo contiene datos mensuales y por especialidad sobre los indicadores que miden el grado de uso de las camas hospitalarias, a saber: giro de camas, intervalo de giro, días paciente, porcentaje de ocupación, días de permanencia, camas disponibles diariamente y egresos diarios.

### **3.7. PROCESAMIENTO Y ANÁLISIS ESTADÍSTICO**

#### **3.7.1. Procesamiento**

El procesamiento de datos se realizó, como se indica bajo el siguiente orden:

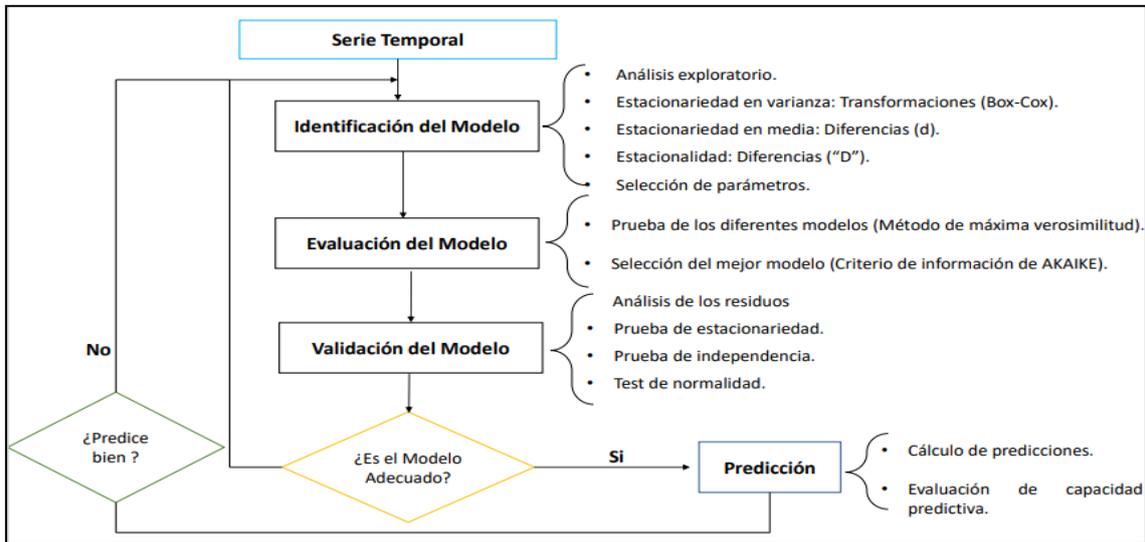
- Revisión y depuración de la base de datos proporcionada por el Departamento de Estadística del Hospital.
- Creación de dos nuevos archivos en Microsoft Excel, uno por cada área (hospitalización y emergencias) con la variable dependiente de interés (ocupación de camas) y la estructura adecuada (datos mensuales).
- Importación de cada uno de los archivos de Microsoft Excel al entorno de desarrollo R, versión 4.2.1, para su posterior procesamiento y análisis.

#### **3.7.2. Análisis estadístico**

En la presente investigación se utilizó la metodología Box-Jenkins para analizar la serie de tiempo correspondiente a la ocupación de camas en las áreas de emergencia y hospitalización del Hospital Básico IESS Puyo, período enero 2018 – septiembre 2022.

La metodología Box-Jenkins, es la más usada en estos casos, ya que, supone que la serie temporal bajo estudio es generada por un proceso estocástico, permitiendo ajustar un modelo matemático para representar el comportamiento de dicha serie, el cual, posteriormente, es útil para hacer predicciones. [27]

En la figura 2, se presenta el esquema usado para la caracterización y construcción de modelos estadísticos, con el fin de obtener el modelo prospectivo que permita determinar la ocupación de camas en el Hospital Básico Puyo del IESS, tomando en cuenta la metodología previamente mencionada.



**Figura 2:** Metodología Box-Jenkins.

Fuente: Adaptado de Gujarati y Porter, 2009.

A continuación, se detallan cada una de las etapas especificadas en la figura 2:

### 1) *Identificación del modelo*

En esta etapa se procedió a verificar la estacionariedad de las series e identificar los parámetros (p, q) y (P, Q) que deben contener los modelos SARIMA de las series para la ocupación de camas en el área de hospitalización y emergencia.

En primer lugar, se realizó un análisis exploratorio para observar el comportamiento de los estadísticos descriptivos: porcentaje mínimo y máximo de ocupación, media y mediana para tener un indicio de la estacionariedad de dichas series.

Para verificar la estacionariedad de las series de tiempo desde enero 2018 a septiembre 2022 se procedió a descomponer cada una de las series en sus cuatro componentes (datos observados, tendencia, estacionalidad y aleatoriedad). Además, se realizó el test de Dickey Fuller y también se graficaron las funciones de correlación simple y parcial para comprobar la presencia de raíces unitarias, para ello se utilizó un nivel de significancia de 0.05, considerando como hipótesis nula ( $H_0$ ) que la serie de tiempo es estacionaria.

Como las dos series de tiempo bajo estudio no son estacionarias se realizó una diferenciación y se graficaron nuevamente las funciones de autocorrelación simple y parcial, también se calculó nuevamente el test de Dickey-Fuller, comprobándose que ambas series ya eran estacionarias.

La identificación de los parámetros se realizó a través de las funciones de autocorrelación simple (ACF) y parcial (PACF) de las series con una diferenciación, para ello se observó el comportamiento de los rezagos. La ACF permite obtener el parámetro  $q$ ; es decir, el número de medias móviles (MA). Por su parte, con la función de autocorrelación parcial (PACF) se determina el número de autorregresores (AR); es decir, el parámetro de orden  $p$ .

Para seleccionar los modelos que pasan a la fase de estimación se procedió a calcular el criterio de información de Akaike (AIC) y el error cuadrático medio (RSME) para todos los modelos propuestos, luego se escogieron cuatro modelos, aquellos con el valor AIC más pequeño y el menor RSME.

## 2) *Evaluación del modelo*

Se estimaron los parámetros para los modelos seleccionados en la etapa de identificación utilizando algoritmos matemáticos iterativos, específicamente mediante el método de máxima verosimilitud.

Para comprobar la significancia de los modelos estimados se consideró como criterio:  $z > 1.96$  y probabilidad  $< 0.05$ . El nivel de significancia establecido para dichas pruebas fue de (5%).

## 3) *Validación del modelo*

El proceso de validación para comprobar la capacidad de ajuste del modelo seleccionado se llevó a cabo a través de:

Análisis de los residuos: se graficaron los residuos, la función de correlación simple (ACF) y el histograma. Con el gráfico de los residuos se observa si se comportan como ruido blanco; es decir, si los valores de la serie en dos tiempos diferentes no están correlacionados. El ACF sirve para verificar que todos los rezagos se encuentren dentro del intervalo de confianza definido (ningún rezago por fuera de las bandas). Finalmente, con el histograma se verifica si los residuos cumplen el supuesto de normalidad.

Prueba de estacionariedad de los residuos: se aplicó el test de Dickey-Fuller bajo las siguientes hipótesis:

$H_0$ : los residuos del modelo SARIMA son estacionarios.

$H_1$ : los residuos del modelo SARIMA no son estacionarios.

Criterio de decisión:

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

Prueba de independencia de los residuos: se realizó con el test de Ljung-Box, contrastando las siguientes hipótesis:

$H_0$ : los residuos del modelo SARIMA son ruido blanco ( $\epsilon_t \sim RB(0, \sigma^2)$ )

$H_1$ : los residuos del modelo SARIMA no son ruido blanco.

Criterio de decisión:

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

Test de normalidad: se comprobó mediante el test de Kolmogórov-Smirnov debido a que el número de registros es mayor a 50. Las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo SARIMA siguen una distribución normal.

$H_1$ : los residuos del modelo SARIMA no siguen una distribución normal.

Criterio de decisión:

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

#### 4) *Predicción/Pronóstico*

En esta última etapa, con los dos modelos estadísticos prospectivos obtenidos en las fases previas, se realizó el pronóstico para enero 2023 – diciembre 2023; con el fin de verificar la calidad predictiva del modelo.

### **3.8. VARIABLES RESPUESTA O RESULTADOS ALCANZADOS**

Para cumplir con lo mencionado en la justificación de presente investigación, así como con los objetivos planteados, el modelado de las series de tiempo se realizó por área, se estimó un modelo para el área de hospitalización y otro para el área de emergencia. En investigaciones futuras se puede considerar el modelamiento de las series de tiempo desde el punto de vista de las especialidades. Es la primera investigación de este tipo que se realiza en el Hospital Básico IESS Puyo y en principio, la idea era ayudar en la toma de decisiones por área, para dar una solución al porcentaje de ocupación de camas.

#### **3.8.1. Variables respuesta**

Las variables usadas para la construcción de los modelos matemáticos fueron:

- Variable dependiente: ocupación de camas (porcentaje).
- Variable independiente: tiempo (en meses).

#### **3.8.2. Resultados alcanzados**

Los resultados alcanzados en la presente investigación son dos modelos prospectivos que van a permitir al personal del Hospital Básico IESS Puyo conocer las proyecciones para el porcentaje de ocupación de camas para el área de hospitalización y emergencia para el período enero 2023 – diciembre 2023 lo cual ayudará al personal del Hospital en el proceso de toma de decisiones y esto a su vez permitirá ofrecer una mejor atención a los afiliados.

En la tabla 2, se presenta la matriz de consistencia de variables.

**Tabla 2:** Matriz de consistencia de variables.

<b>Objetivo general</b>	<b>Hipótesis general</b>	<b>Variables</b>	<b>Indicadores</b>	<b>Técnicas</b>	<b>Instrumentos</b>
Plantear un modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS.	El modelo estadístico prospectivo para determinar la ocupación de camas en el Hospital Básico Puyo del IESS es significativo.	<p><b>Variable Independiente</b></p> <p>Tiempo</p> <p><b>Variable Dependiente</b></p> <p>Ocupación de camas.</p>	<ul style="list-style-type: none"> <li>• Meses</li> <li>• Total días paciente.</li> <li>• Días camas disponibles.</li> </ul>	Series de Tiempo. (univariante)	Registros Departamento de Estadística del Hospital (enero 2018 – septiembre 2022)

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo

## CAPÍTULO IV

### RESULTADOS Y DISCUSIÓN

#### 4.1. INTRODUCCIÓN

En este capítulo se presentan los resultados obtenidos al modelar la serie de tiempo para la ocupación de camas del Hospital Básico IESS Puyo en el área de hospitalización y de emergencias, en el período comprendido entre enero de 2018 y septiembre 2022, utilizando la metodología Box-Jenkins. Por otra parte, se realizan predicciones para un período de doce meses, de enero a diciembre de 2023.

#### 4.2. VARIABLES Y ESTRUCTURA DE LA BASE DE DATOS

En la tabla 3 se muestra cómo se organizó la base de datos en la presente investigación, la cual está conformada por dos variables. El tiempo, medido en meses, representa la variable independiente, y es de tipo categórica, mientras que la variable ocupación de camas, medida en porcentaje, que es de tipo numérica, corresponde a la variable dependiente. La base de datos contiene 57 registros.

**Tabla 3:** Configuración de la base de datos.

Meses	Ocupación %
Enero	93.5
Febrero	93.4
Marzo	95.1
Abril	85.9
.	
.	
Septiembre	62.2

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### 4.3. MODELADO DE LA OCUPACIÓN DE CAMAS EN EL ÁREA DE HOSPITALIZACIÓN SEGÚN LA METODOLOGÍA BOX-JENKINS

#### 4.3.1. Identificación del modelo

En esta fase se seleccionó el mejor modelo SARIMA para la ocupación de camas en el área de hospitalización del Hospital Básico IESS Puyo.

##### *Análisis exploratorio*

En la figura 3 se presentan los datos correspondientes a la ocupación de camas una vez transformados en una serie de tiempo, observándose que el porcentaje medio de ocupación para el período analizado es de 75.76%, con un mínimo y máximo de 27.20% y 113.70%, respectivamente. Así mismo, se tiene que el 25% y 75% de ocupación de camas en hospitalización es igual o inferior a 61.30% y 90.70%, respectivamente. En general, se aprecia que la serie no presenta una única tendencia en el tiempo, ya que es más o menos estable al comienzo, luego presenta una tendencia decreciente para el año 2020 hasta al final cuando de nuevo muestra una tendencia creciente, y a partir de allí, se mantiene estable.



**Figura 3:** Serie de tiempo de la ocupación de camas en el área de hospitalización.

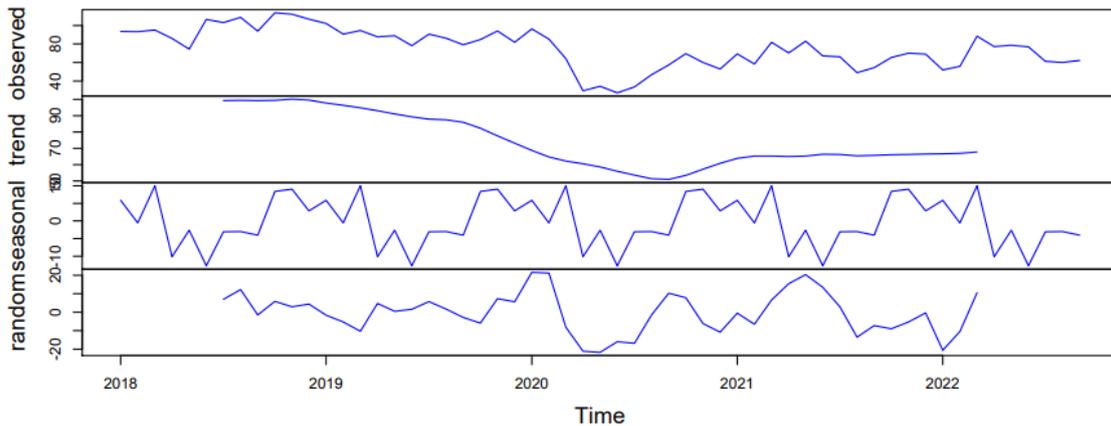
Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

##### *Descomposición de la serie*

En la figura 4 se muestra la descomposición de la serie original en sus cuatro (04) componentes: serie original (observed), residuos (random), estacionalidad (seasonal) y tendencia (trend); con el fin de observar dichos componentes de forma individual para comprobar si cumplen los supuestos del modelo SARIMA, específicamente la

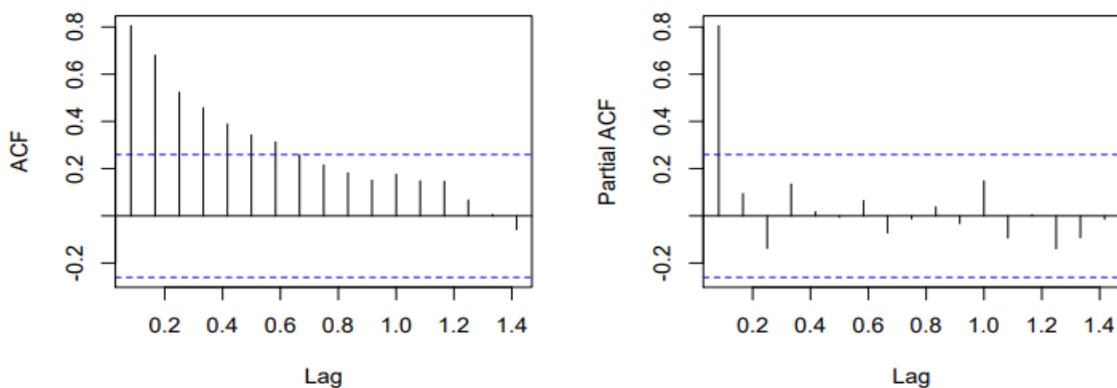
estacionariedad y la estacionalidad. En el gráfico correspondiente a la tendencia, se tiene que la serie no es estacionaria ya que presenta una tendencia decreciente, siendo necesario transformarla o diferenciarla. En cuanto al componente estacional, el gráfico muestra un patrón estacional que se repite cada 12 meses. Finalmente, los residuos indican la no estacionariedad de la serie, los residuos no están cercanos a cero.



**Figura 4.** Descomposición de la serie correspondiente a la ocupación de camas. Elaborado por: Gavilanes, 2022. Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### Correlogramas

Las funciones de autocorrelación simple (ACF) y parcial (PACF) para la serie original se muestran en la figura 5, observándose que la ACF converge a cero lentamente y la PACF presenta un valor cercano a uno para el primer rezago, lo cual indica la presencia de raíces unitarias.



**Figura 5:** Funciones de autocorrelación simple (ACF) y parcial (PACF). Elaborado por: Gavilanes, 2022. Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### *Verificación de estacionariedad*

Para comprobar la presencia de raíces unitarias se aplicó el test de Dickey-Fuller Aumentado, utilizando un nivel de significancia  $\alpha = 0.05$ . Las hipótesis contrastadas fueron:

$H_0$ : la serie no es estacionaria (presencia de raíz unitaria)

$H_1$ : la serie es estacionaria (no posee raíz unitaria)

El criterio de decisión fue el siguiente:

p valor  $< 0.05$  Rechazar  $H_0$ .

p valor  $\geq 0.05$  No Rechazar  $H_0$ .

En la tabla 4 se presenta los resultados del test, observándose que el p valor es 0.4178, por tanto, no se rechaza la hipótesis nula la serie no es estacionaria.

**Tabla 4:** Test de Dickey - Fuller.

---

Dickey-Fuller = -2.3888	Orden de retraso = 3	p_valor = 0.4178
Hipótesis alternativa: Estacionaria		

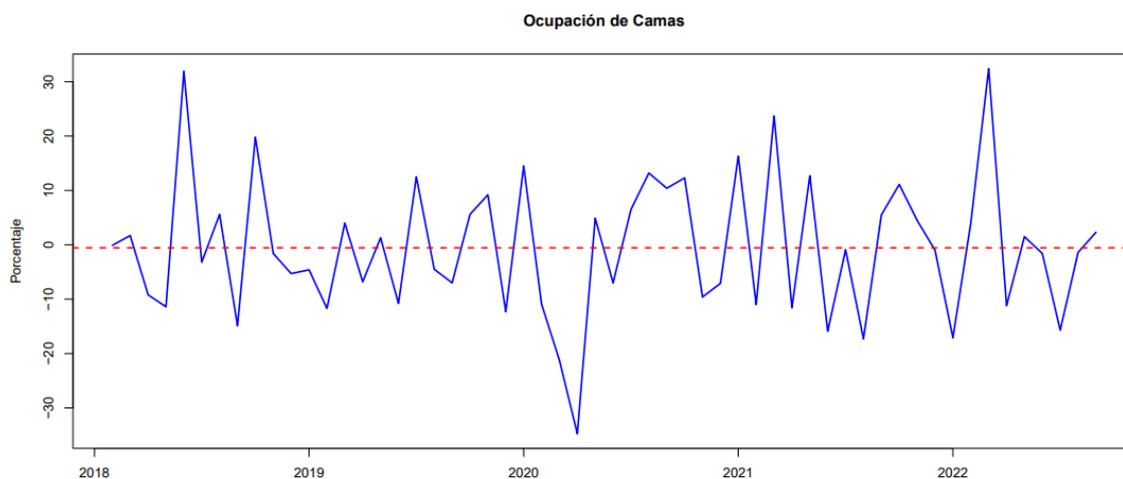
---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### *Análisis de estacionariedad en media y varianza*

Al verificar que la serie no es estacionaria, se requiere diferenciarla. En la figura 6 se muestra el comportamiento de la serie de tiempo con una diferencia, observándose que la serie es estacionaria porque la media y la varianza son constantes a lo largo del periodo evaluado.

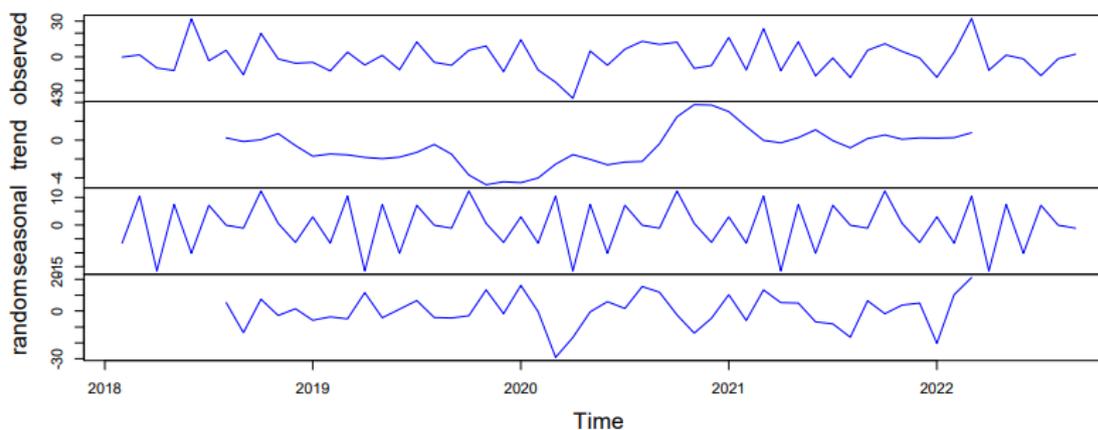


**Figura 6:** Serie de tiempo de ocupación de camas estacionaria

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En la figura 7 se muestran los componentes de tendencia y estacionalidad para la serie bajo estudio luego de ser diferenciada. Se aprecia que se ha eliminado la tendencia decreciente que presentaba la serie original, siendo otro indicio de estacionalidad.



**Figura 7:** Componentes de la serie de ocupación de camas estacionaria.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

Para verificar lo observado gráficamente se aplica el test de Dickey-Fuller a la serie diferenciada (tabla 5), obteniéndose un p valor de 0.01, el cual es menor al nivel de significancia establecido ( $\alpha = 0.05$ ); por tanto, se rechaza la hipótesis nula, concluyendo que la serie para la ocupación de camas en el área de hospitalización con una diferenciación es estacionaria.

**Tabla 5:** Test Dickey-Fuller de la serie diferenciada.

---

Dickey-Fuller = -4.2045	Orden de retraso = 3	p_valor = 0.01
-------------------------	----------------------	----------------

---

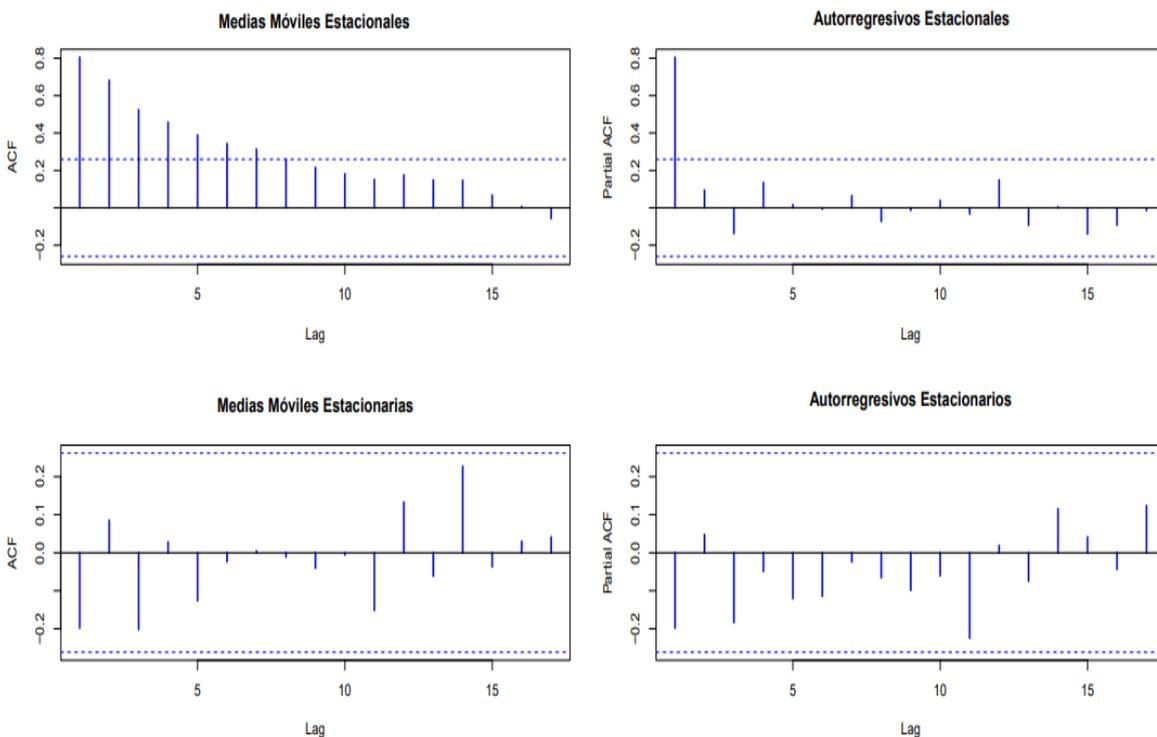
Hipótesis alternativa: Estacionaria

---

Elaborado por: Gavilanes, 2022.  
Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

*Parámetros*

Una vez que la serie es estacionaria, se procede a identificar los valores de los parámetros (p, q) y (P, Q) mediante las funciones de autocorrelación simple y parcial que se muestran en la figura 8. En la parte estacionaria, no se observan retardos significativos en el ACF y PACF; no obstante, en ambos gráficos hay un retardo cercano a la línea azul, razón por la cual se recomienda probar con una media móvil de orden q = (0 o 1) y un autorregresivo de orden p = (0 o 1), respectivamente. En la parte estacional, en el ACF se tienen varios rezagos significativos; se debe usar media móvil de orden Q = (0, 1, 2 o 3) y en la parte autorregresiva estacional se observa que no hay rezagos significativos, sin embargo, se toma P = (0 o 1).



**Figura 8:** Correlogramas ACF y PACF para la serie original y diferenciada.  
Elaborado por: Gavilanes, 2022.  
Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En función de lo anterior, en las tablas 6 y 7 se presentan los posibles modelos a probar, de los cuales se seleccionará aquel modelo cuyo valor del criterio de información de AKAIKE (AIC) sea el más pequeño y con el menor error cuadrático medio (RMSE).

**Tabla 6:** Modelos ARIMA propuestos.

Nombre	Modelos	AIC	RMSE
Modelo 1	AUTO.ARIMA (0,1,0)	446.29	12.67
Modelo 2	ARIMA (0,1,1)	446.27	12.44
Modelo 3	ARIMA (1,1,0)	446.14	12.42
Modelo 4	ARIMA (1,1,1)	447.30	12.33

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

La función del lenguaje de programación R, conocida como AUTO.ARIMA da indicios del mejor modelo para la serie bajo estudio. En vista de que dicha función arrojó un modelo ARIMA, se proponen cuatro modelos (tabla 6). Se seleccionaron dos de ellos en función del criterio AIC y el RMSE, a saber: ARIMA (1, 1, 0) con el menor AIC = 446.14 y el modelo ARIMA (1, 1, 1) con el menor error cuadrático medio (RMSE =12.33); sin embargo, el modelo ARIMA (1, 1, 0), en la etapa de estimación arrojó que los parámetros no son significativos, por tal razón, se descartó. Por su parte, el modelo ARIMA (1, 1, 1) cumple con todos los supuestos: estacionariedad, independencia (ruido blanco) y normalidad, pero, en la etapa de pronóstico no es el adecuado (Anexo 1).

Por lo mencionado previamente y tomando en cuenta la información de los gráficos de autocorrelación simple y parcial de la figura 7 se proponen algunos modelos SARIMA para la ocupación de camas en el área de hospitalización, ya que, como se mencionó con anterioridad, hay un componente estacional presente.

**Tabla 7:** Modelo SARIMA propuestos.

Nombre	Modelos	AIC	RMSE
Modelo 5	SARIMA (1,1,1) (0,0,1) [12]	448.52	12.21
Modelo 6	SARIMA (1,1,1) (0,0,2) [12]	450.51	12.21
Modelo 7	SARIMA (1,1,1) (0,0,3) [12]	449.79	11.05
Modelo 8	SARIMA (1,1,1) (1,0,0) [12]	448.55	12.22
Modelo 9	SARIMA (1,1,1) (1,0,1) [12]	450.51	12.21

Modelo 10	SARIMA (1,1,1) (1,0,2) [12]	452.49	12.21
Modelo 11	SARIMA (1,1,1) (1,0,3) [12]	453.95	10.78
Modelo 12	SARIMA (0,1,0) (0,0,1) [12]	447.00	12.49
Modelo 13	SARIMA (0,1,0) (0,0,2) [12]	448.91	12.47
Modelo 14	SARIMA (0,1,0) (0,0,3) [12]	449.95	11.86
Modelo 15	SARIMA (0,1,0) (1,0,0) [12]	446.96	12.48
Modelo 16	SARIMA (0,1,0) (1,0,1) [12]	448.96	12.48
Modelo 17	SARIMA (0,1,0) (1,0,2) [12]	450.17	11.51
Modelo 18	SARIMA (0,1,0) (1,0,3) [12]	451.61	10.21
Modelo 19	SARIMA (0,1,1) (0,0,1) [12]	447.34	12.31
Modelo 20	SARIMA (0,1,1) (0,0,2) [12]	449.34	12.31
Modelo 21	SARIMA (0,1,1) (0,0,3) [12]	450.68	11.95
Modelo 22	SARIMA (0,1,1) (1,0,0) [12]	447.37	12.31
Modelo 23	SARIMA (0,1,1) (1,0,1) [12]	449.34	12.31
Modelo 24	SARIMA (0,1,1) (1,0,2) [12]	451.15	12.13
Modelo 25	SARIMA (0,1,1) (1,0,3) [12]	452.57	11.45
Modelo 26	SARIMA (1,1,0) (0,0,1) [12]	447.29	12.30
Modelo 27	SARIMA (1,1,0) (0,0,2) [12]	449.29	12.30
Modelo 28	SARIMA (1,1,0) (0,0,3) [12]	450.74	12.01
Modelo 29	SARIMA (1,1,0) (1,0,0) [12]	447.33	12.31
Modelo 30	SARIMA (1,1,0) (1,0,1) [12]	449.29	12.30
Modelo 31	SARIMA (1,1,0) (1,0,2) [12]	451.29	12.30
Modelo 32	SARIMA (1,1,0) (1,0,3) [12]	452.63	11.55

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

De la tabla 7 se obtiene que el modelo SARIMA (0,1,0) (1,0,0) [12] es el que presenta menor AIC =446.96 y el SARIMA (1,1,1) (1,0,3) [12] es el modelo con menor error cuadrático medio, por tanto, se consideran esos dos modelos para la etapa de estimación de parámetros. El modelo (18) con RMSE muy cercano a 10.78 se probó y el coeficiente estimado no resultó significativo.

### 4.3.2 Estimación de los parámetros del modelo

En esta etapa se estiman los parámetros para los dos modelos seleccionados usando el método de máxima verosimilitud. Las tablas 8 y 9, muestran los resultados de tal estimación.

**Tabla 8:** Estimación de parámetros para el modelo SARIMA (0, 1, 0) (1, 0, 0) [12].

<b>SARIMA (0,1,0) (1,0,0) [12]</b>					
<b>sar1</b>					
Coefficientes	0.1713				
Error estándar	0.1466				
$\sigma^2$	161.4	Probabilidad de registro =		-221.48	
AIC = 446.96	AICc = 447.19	BIC = 451.01			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-0.4322501	12.47866	9.607876	-2.612742	14.65731	0.4696034

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

**Tabla 9:** Estimación de parámetros para el modelo SARIMA (1, 1, 1) (1, 0, 3) [12].

<b>SARIMA (1,1,1) (1,0,3) [12]</b>						
	<b>ar1</b>	<b>ma1</b>	<b>sar1</b>	<b>sma1</b>	<b>sma2</b>	<b>sma3</b>
Coefficientes	-0.7593	0.6108	-0.8733	1.2595	0.2850	-0.2522
Error estándar	0.3465	0.4295	2.0111	4.2618	1.7019	0.6536
$\sigma^2$	132.5	Probabilidad de registro =		-219.97		
AIC = 453.95	AICc = 456.28	BIC = 468.13				
Medidas de error en el conjunto de entrenamiento						
ME	RMSE	MAE	MPE	MAPE	MASE	
-0.4546875	10.78275	7.963639	-2.434103	12.04199	0.3892381	

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

donde:

ar: autorregresivos en la parte estacionaria (p).

ma: medias móviles en la parte estacionaria (q)

sar: autorregresivos en la parte estacional (P)

sma: número de medias móviles en la parte estacional (Q)

AIC: criterio de información AKAIKE.

BIC: criterio de información Bayesiano.

### Significancia de los parámetros

Para comprobar si las estimaciones son significativas se considera como criterio:  $|z| > 1.96$  y  $p < 0.05$ . Para el modelo SARIMA (0,1,0) (1,0,0) [12] se observa que el parámetro no es significativo porque no cumple con el criterio establecido, descartándose dicho modelo (tabla 10).

**Tabla 10:** Significancia de los parámetros modelo SARIMA (0, 1, 0) (1, 0, 0) [12].

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
sar1	0.17127	0.14662	1.1681	0.2428

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En cuanto al modelo SARIMA (1, 1, 1) (1, 0, 3) [12], se tiene que el parámetro ar1 es significativo (z valor =2.2428) y (Pr =0.02491) (tabla 11).

**Tabla 11:** Significancia de los parámetros del modelo SARIMA (1, 1, 1) (1, 0, 3) [12].

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	-0.79034	0.35239	-2.2428	0.02491 *
ma1	0.67998	0.42976	1.5822	0.11360
sra1	-0.87334	2.01106	-0.4343	0.66409
sma1	1.25945	4.26179	0.2955	0.76759
sma2	0.28503	1.70192	0.1675	0.86699
sma3	-0.25219	0.65362	-0.3858	0.69961

Códigos de significancia: 0 '\*\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 '' 1

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

La ecuación del modelo SARIMA queda expresada de la siguiente manera:

$$Y_t = \varphi_1 Y_{t-1} + \epsilon_t$$

Tomando en cuenta las estimaciones de la tabla 11, la ecuación de pronóstico para la ocupación de camas en el área de hospitalización viene dada por:

$$\Delta Y_t = -0.79034 Y_{t-1} + \epsilon_t$$

donde:

$Y_t$ : Pronóstico mensual de la ocupación de camas.

$\varphi_1$ : parámetro del modelo SARIMA.

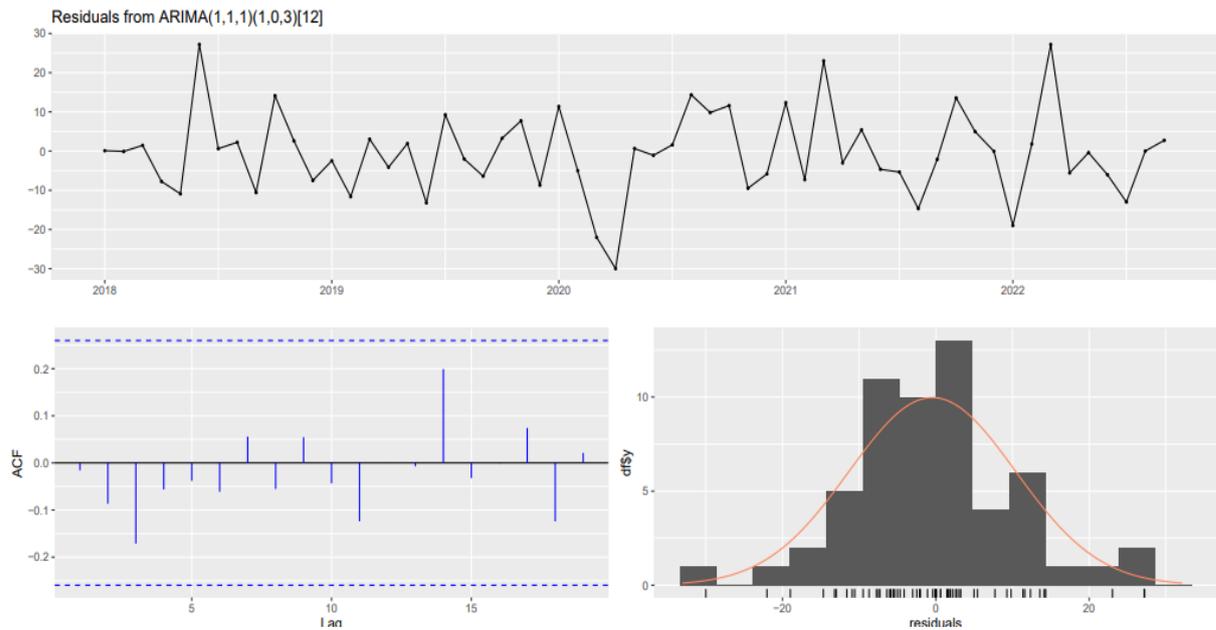
$\epsilon_t$ : error de ruido blanco.

#### **4.3.2. Evaluación del modelo**

En esta etapa se evalúan los residuos mediante un análisis gráfico y pruebas de estacionariedad e independencia, así como con el test de normalidad.

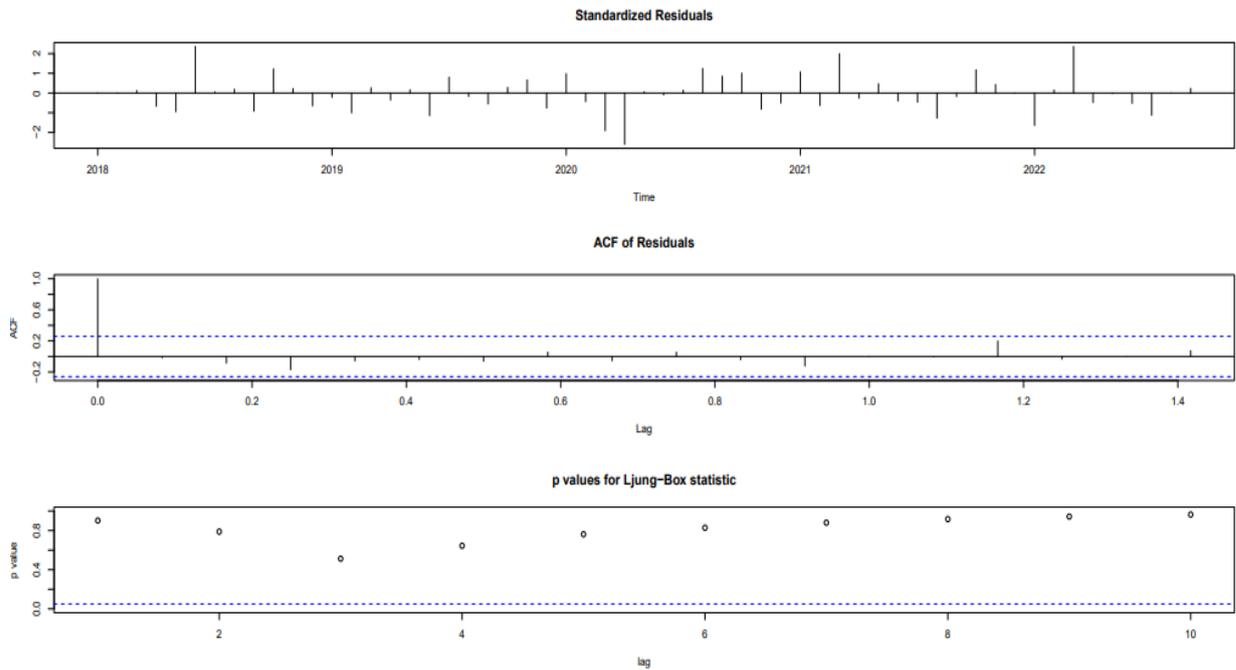
##### *Análisis gráfico de los residuos*

En la figura 9 se presentan tres gráficos que permiten observar el comportamiento de los residuos. El primer gráfico corresponde a los residuos, indicando que son ruido blanco; con media cero e igual varianza. Por otro lado, se tiene la función de autocorrelación simple (ACF), la cual indica que los residuos son aleatorios ya que ningún rezago está por fuera de las bandas (intervalos de confianza). Por último, los residuos del modelo SARIMA (1,1,1)(1,0,3)[12] siguen aproximadamente una distribución normal.



**Figura 9:** Análisis gráfico del modelo SARIMA (1, 1, 1) (1, 0, 3) [12].  
 Elaborado por: Gavilanes, 2022.  
 Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

Para complementar el análisis gráfico, en la figura 10 se muestran tres gráficos. El primero de ellos muestra los residuos estandarizados, observándose que estos no exhiben un patrón (son aleatorios), son ruido blanco. El segundo gráfico, muestra el ACF, apreciándose que ningún rezago es significativo (todos se encuentran dentro de los intervalos de confianza). En el tercer gráfico, se reflejan los valores p del estadístico de Ljung-Box, observándose que todos los residuos están por encima del nivel de significancia establecido de 0.05, corroborando nuevamente que estos son ruido blanco. En general, se puede decir que el modelo SARIMA (1,1,1)(1,0,3)[12] se ajusta bien.



**Figura 10:** Diagnóstico del modelo SARIMA.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### *Prueba de estacionariedad de los residuos*

Para comprobar la estacionariedad de los residuos se aplicó la prueba de Dickey-Fuller.

Las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo SARIMA (1,1,1) (1,0,3)[12] no son estacionarios.

$H_1$ : los residuos del modelo SARIMA (1,1,1) (1,0,3)[12] son estacionarios.

Criterio de decisión

p valor < 0.05 Rechaza  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

En la tabla 12 se presentan los resultados de la prueba, observándose que el p valor es menor al nivel de significancia ( $\alpha=0.05$ ); por tanto, se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA (1,1,1) (1,0,3)[12] son estacionarios.

**Tabla 12:** Test de Dickey-Fuller para los residuos del modelo SARIMA.

---

Datos: Modelo 11\$residuals

Dickey-Fuller = - 4.3688                      Orden de retraso = 3                      p\_valor = 0.01

Hipótesis alternativa: Estacionaria

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

*Prueba de independencia de los residuos*

La independencia de los residuos se comprobó mediante el test de Ljung-Box, con un nivel de significancia de 0.05. Para esta prueba, se contrastaron las siguientes hipótesis:

$H_0$ : los residuos del modelo SARIMA(1,1,1)(1,0,3)[12] son ruido blanco ( $\epsilon_t \sim RB(0, \sigma^2)$ )

$H_1$ : los residuos del modelo SARIMA (1,1,1) (1,0,3)[12] no son ruido blanco.

Criterio de decisión

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

En la tabla 13 se presentan los resultados de la prueba, observándose que el p valor es de 0.9024, mayor al nivel de significancia ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA (1,1,1) (1,0,3)[12] son independientes, es decir, se comportan como ruido blanco.

**Tabla 13:** Test de Ljung-Box para los residuos del modelo SARIMA.

---

Datos: Residuos del modelo SARIMA (1,1,1) (1,0,3)[12]

X-cuadrado = 0.015034,                      Grados de libertad = 1,                      p\_valor = 0.9024

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

*Prueba de normalidad*

Para verificar la normalidad de los residuos se aplicó el test de Kolmogórov-Smirnov debido a que el número de registros es mayor a 50. En este caso, las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo SARIMA(1,1,1)(1,0,3)[12] siguen una distribución normal.

$H_1$ : los residuos del modelo SARIMA(1,1,1)(1,0,3)[12] no siguen una distribución normal.

Criterio de decisión

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

En la tabla 14 se presentan los resultados de la prueba. En ellos se puede observar que el p valor es 0.3467, mayor al nivel de significancia ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA(1,1,1)(1,0,3)[12] siguen una distribución normal.

**Tabla 14:** Test de Kolmogorov-Smirnov para los residuos del modelo SARIMA.

---

Datos: Residuos del modelo SARIMA(1,1,1)(1,0,3)[12]

$D = 0.12095$ ,       $p\_valor = 0.3467$

Hipótesis alternativa: dos colas (bilateral)

---

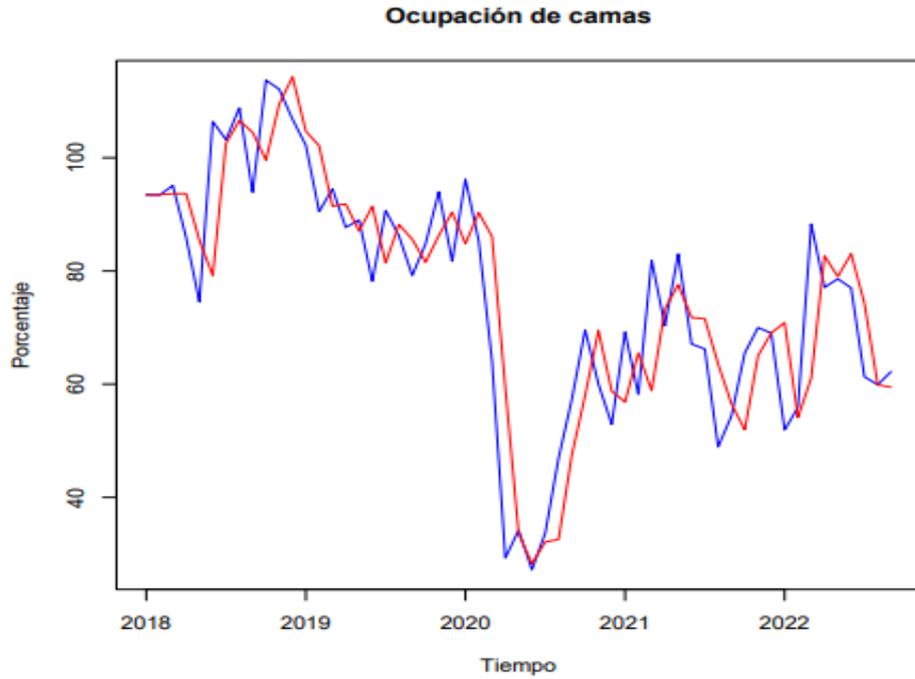
Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

La evaluación realizada a los residuos del modelo SARIMA(1,1,1)(1,0,3)[12] arrojó que estos cumplen con todos los supuestos mencionados previamente, por tanto, se pasa a la etapa de predicción (pronóstico).

#### **4.3.4 Predicción a través del modelo desarrollado para el área de hospitalización**

En esta etapa se procedió a comparar la serie original (línea azul) con los valores ajustados por el mejor modelo (línea roja) como se muestra en la figura 11. Se puede apreciar que el modelo SARIMA (1,1,1)(1,0,3)[12] se ajusta adecuadamente a la serie de tiempo de ocupación de camas en el área de hospitalización del Hospital Básico IESS Puyo.



**Figura 11:** Comparación de la serie original con los valores ajustados por el modelo SARIMA.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En la tabla 15 se presenta la comparación de los pronósticos para los dos grupos considerados, entrenamiento y valores reales para validar los pronósticos realizados con el modelo SARIMA (1, 1, 1) (1, 0, 3) [12]. La comparación arrojó que existen diferencias significativas en los meses de agosto (2021), septiembre (2021), enero (2022) y febrero (2022), los demás meses se puede decir que el modelo predice satisfactoriamente en un 87.16%.

**Tabla 15:** Cotejo entre los datos de entrenamiento y testeo.

Meses	Testeo	Entrenamiento	Error
Julio (2021)	66.2	70.72	-6.83
Agosto (2021)	48.9	70.12	- 43.39
Septiembre (2021)	54.4	75.26	- 38.35
Octubre (2021)	65.5	71.62	- 9.34
Noviembre (2021)	70.0	71.75	- 2.50
Diciembre (2021)	69.0	70.23	- 1.78
Enero (2022)	51.9	76.53	- 47.46

Febrero (2022)	55.9	76.60	- 37.03
Marzo (2022)	88.3	79.00	10.53
<b>PROMEDIO</b>	63.34	73.54	

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En la tabla 16 se presentan los pronósticos obtenidos con el modelo SARIMA(1,1,1)(1,0,3)[12] con los intervalos de confianza del 80% y 95%. Para efectos de la investigación, se consideran los intervalos del 95%.

**Tabla 16:** Pronóstico de la ocupación de camas en el área de hospitalización.

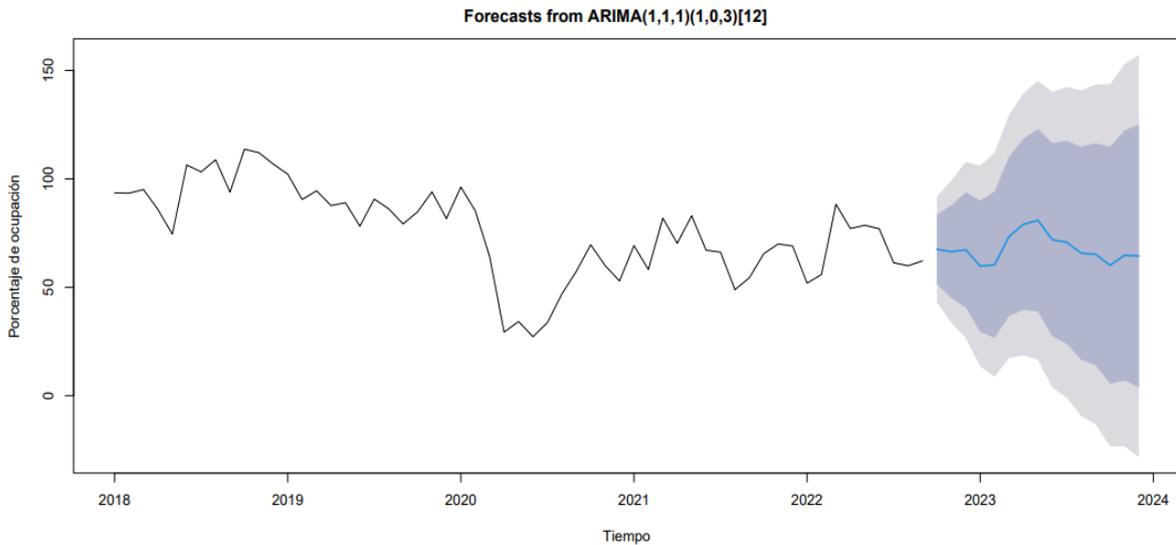
Meses	Pronóstico (%)	Límite inferior 80%	Límite superior 80%	Límite inferior 95%	Límite superior 95%
Enero	59.77	29.52	90.03	13.50	106.04
Febrero	60.40	26.65	94.14	8.79	112.01
Marzo	73.39	36.75	110.03	17.36	129.42
Abril	79.08	39.56	118.59	18.64	139.51
Mayo	80.89	38.84	122.94	16.58	145.20
Junio	71.94	27.39	116.50	3.80	140.09
Julio	70.75	23.91	117.58	- 0.88	142.38
Agosto	65.68	16.60	114.77	- 9.38	140.75
Septiembre	65.23	14.06	116.40	- 13.03	143.49
Octubre	60.11	5.51	114.70	- 23.39	143.60
Noviembre	64.71	7.10	122.33	- 23.40	152.82
Diciembre	64.45	3.81	125.08	- 28.29	157.18

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En la figura 12 se muestra las proyecciones para la ocupación de camas en el área de hospitalización según el modelo SARIMA. La línea de color negro corresponde a la serie de tiempo bajo estudio y la línea azul representa la media del pronóstico para el porcentaje de ocupación de camas por mes. Además, se tiene el color gris oscuro y gris claro que se refieren a los intervalos de confianza del 80% y 95%, respectivamente. Se observa que el modelo SARIMA para el período pronosticado se comporta como la serie original; en los

primeros meses del 2023 el porcentaje de ocupación aumenta hasta el mes de agosto que comienza a disminuir. Su valor más alto se refleja en el mes de mayo.



**Figura 12:** Pronósticos.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

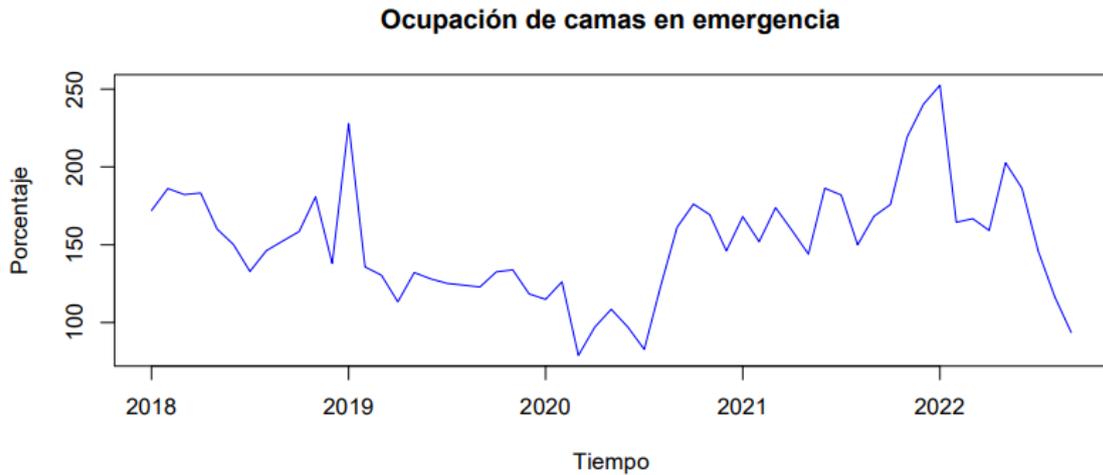
#### **4.4. MODELADO DE LA OCUPACIÓN DE CAMAS EN EL ÁREA DE EMERGENCIAS SEGÚN LA METODOLOGÍA BOX-JENKINS.**

##### **4.4.1. Identificación del modelo**

En esta fase se seleccionó el mejor modelo SARIMA para la ocupación de camas en el área de emergencias del Hospital Básico IESS Puyo.

##### *Análisis exploratorio*

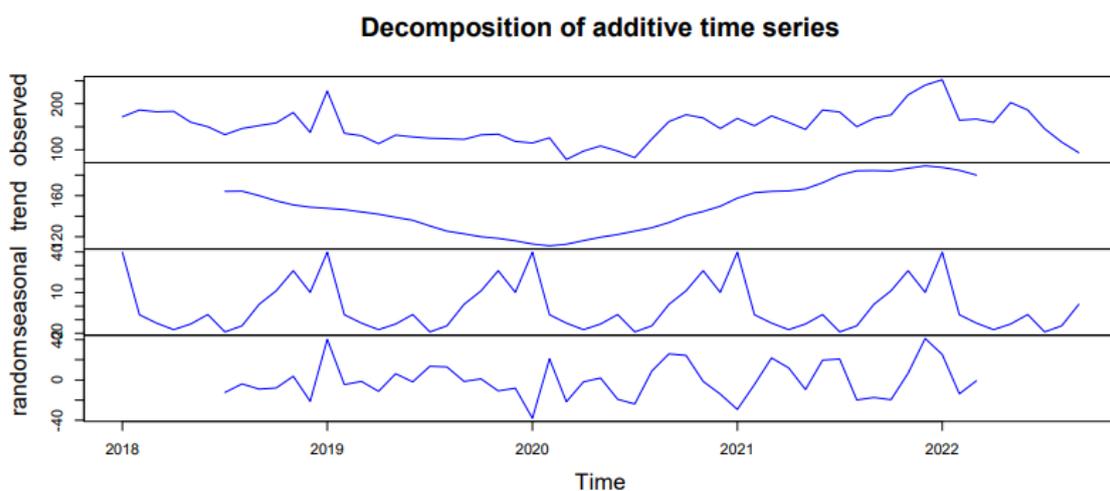
En la figura 13 se presenta los datos correspondientes a la ocupación de camas una vez transformados en una serie de tiempo, observándose que, el porcentaje medio de ocupación para el período analizado es de 150.1%, con un mínimo y máximo de 78.9% y 252.4%, respectivamente. Por otra parte, se tiene que el 25% y 75% de ocupación de camas en emergencia es igual o inferior a 126.2% y 173.8%, respectivamente. En general, se observa que la tendencia de la serie varía para el periodo analizado, al comienzo decrece adquiriendo su menor valor en los meses de marzo y abril del 2020 y, posteriormente se aprecia una tendencia creciente.



**Figura 13:** Serie de tiempo de la ocupación de camas en el área de emergencia. Elaborado por: Gavilanes, 2022. Fuente: Datos del área de emergencia del Hospital Básico Puyo.

*Descomposición de la serie*

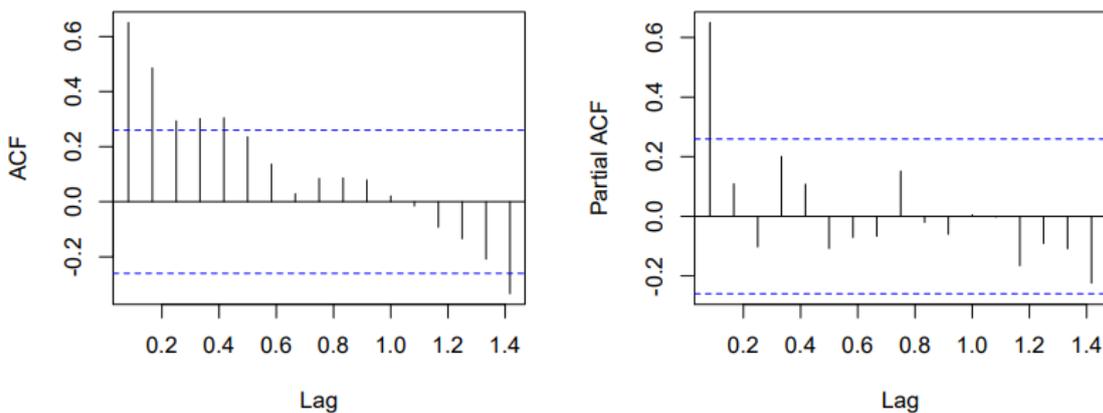
En la figura 14 se muestra la descomposición de la serie original en sus cuatro (04) componentes. En cuanto a la tendencia (tren), se observa que no es estacionaria, antes del año 2020 muestra una tendencia decreciente, y después, es creciente, por tanto, se debe diferenciar para corregir el comportamiento de la tendencia. En cuanto al componente estacional, el gráfico muestra un patrón estacional que se repite cada 12 meses. Por otro lado, los valores de los residuales se encuentran alejados del cero, lo que indica la no estacionariedad de la serie.



**Figura 14:** Descomposición de la serie en sus componentes. Elaborado por: Gavilanes, 2022. Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### Correlogramas

En la figura 15 se muestran las funciones de autocorrelación simple (ACF) y parcial (PACF) para la serie original, apreciándose que la ACF converge a cero lentamente y, la PACF presenta un valor cercano a uno para el rezago  $k=1$ , lo cual indica la presencia de raíces unitarias.



**Figura 15:** Funciones de autocorrelación simples (ACF) y parcial (ACF) de la serie.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### Verificación de estacionariedad

Para comprobar la presencia de raíces unitarias se aplicó el test de Dickey-Fuller Aumentado, utilizando un nivel de significancia  $\alpha = 0.05$ . Las hipótesis contrastadas fueron:

$H_0$ : la serie no es estacionaria (presencia de raíz unitaria)

$H_1$ : la serie es estacionaria (no posee raíz unitaria)

El criterio de decisión fue el siguiente:

p valor  $< 0.05$  Rechazar  $H_0$ .

p valor  $\geq 0.05$  No Rechazar  $H_0$ .

En la tabla 17 se presenta los resultados del test observándose que el valor p es 0.5085, por tanto, no se rechaza la hipótesis nula y la serie no es estacionaria.

**Tabla 17:** Test de Dickey – Fuller

---

Dickey-Fuller = -2.1638                      Orden de retraso = 3                      p\_valor = 0.5085

Hipótesis alternativa: Estacionaria

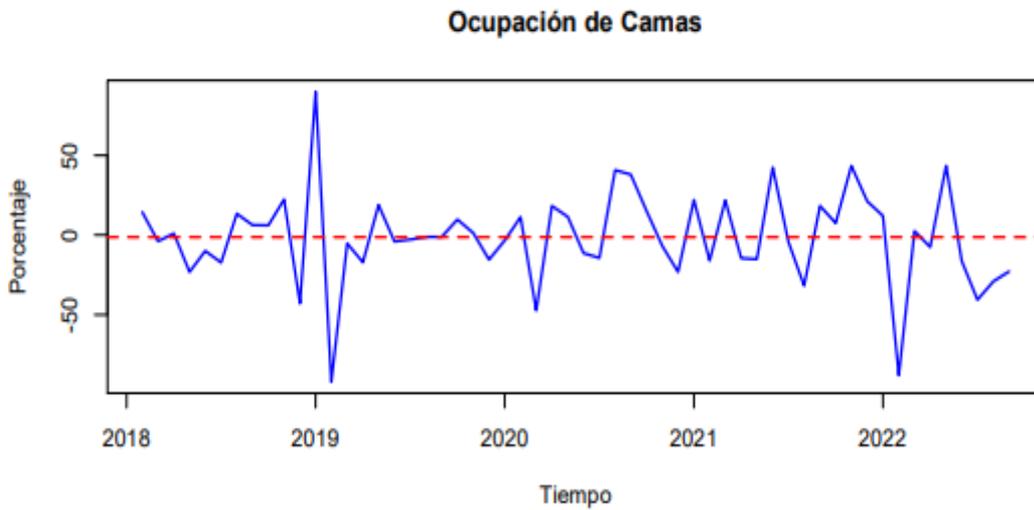
---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

*Análisis de estacionariedad en media y varianza*

Como la serie no es estacionaria, debe ser diferenciada. En la figura 16 se muestra el comportamiento de la serie de tiempo con una diferenciación, observándose que es estacionaria en media y la varianza es constante a lo largo del tiempo.

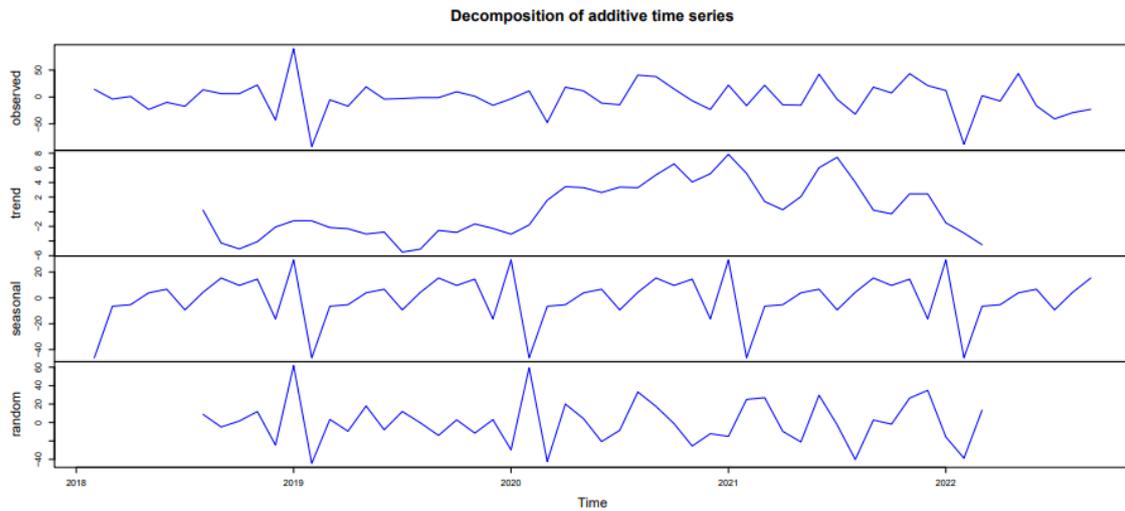


**Figura 16:** Serie de tiempo diferenciada una vez.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

En la figura 17 se muestran los componentes de la serie con una diferenciación, observándose que la tendencia se ha eliminado.



**Figura 17:** Descomposición de la serie con una diferenciación.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Una vez diferenciada la serie, se verifica a través del test de Dickey-Fuller la estacionariedad observada gráficamente. El p valor de 0.01 es menor al nivel de significancia establecido ( $\alpha = 0.05$ ), por tanto, se rechaza la hipótesis nula y se concluye que la serie para la ocupación de camas en el área de emergencias con una diferenciación es estacionaria (tabla 18).

**Tabla 18:** Test de Dickey-Fuller para la serie con una diferenciación.

---

Dickey-Fuller = -4.6737                      Orden de retraso = 3                      p\_valor = 0.01

Hipótesis alternativa: Estacionaria

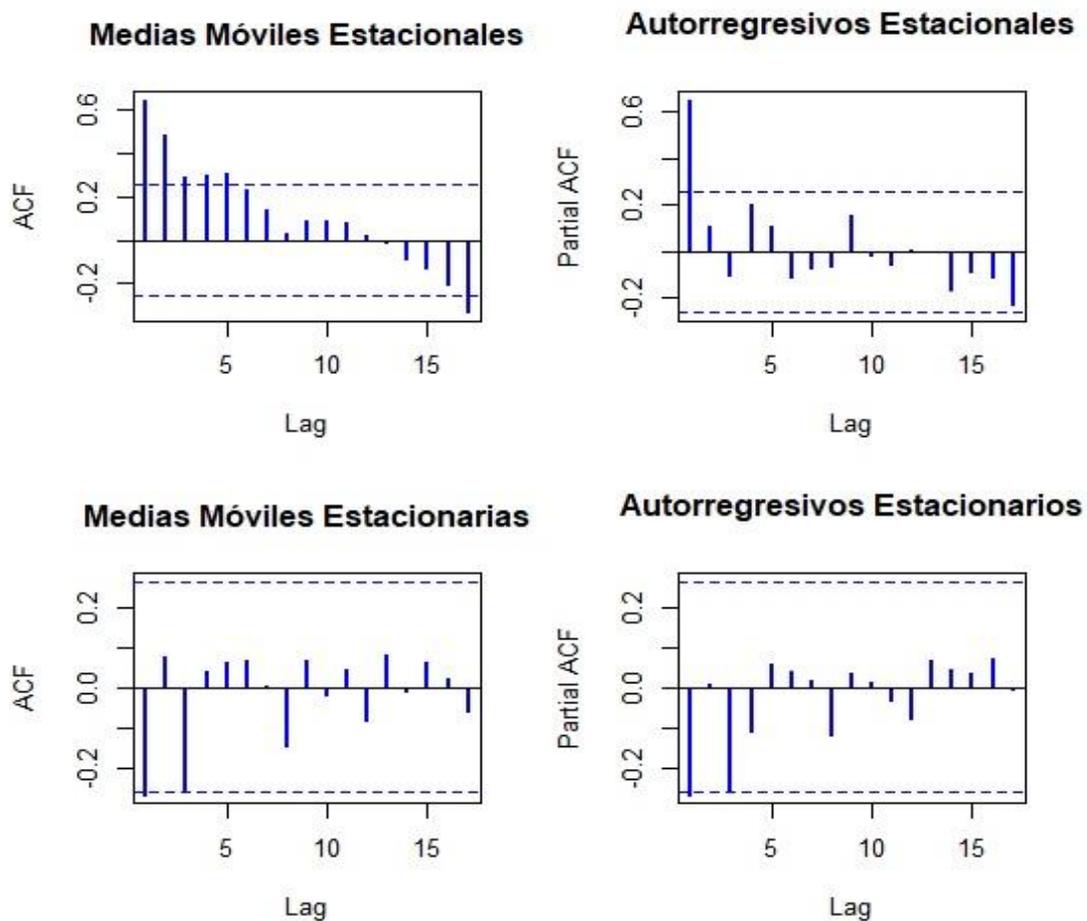
---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

## Parámetros

Se procede a identificar los valores de los parámetros  $(p, q)$  y  $(P, Q)$  mediante las funciones de autocorrelación simples y parciales (figura 18). En la parte estacionaria se observan dos retardos significativos en el ACF y PACF, se prueba con una media móvil de orden  $q = (0, 1 \text{ o } 2)$  y un autorregresivo de orden  $p = (0, 1 \text{ o } 2)$ . En la parte estacional, en el ACF se tienen varios rezagos significativos, por lo tanto, se usa media móvil de orden  $Q = (0, 1 \text{ o } 2)$ , y en la parte autorregresiva estacional se sugiere probar con un autorregresivo de orden  $P = (0 \text{ o } 1)$ , a pesar de que no se tienen rezagos significativos; sin embargo, hay uno muy cercano a la línea azul.



**Figura 18:** Funciones de autocorrelación simple y parcial de la serie original y con una diferenciación.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

La función del lenguaje de programación R, conocida como AUTO.ARIMA da indicios del mejor modelo para la serie bajo estudio. En vista de que dicha función arrojó un modelo ARIMA, en la tabla 19 se proponen seis modelos. Se selecciona el modelo ARIMA (1,0,0) por tener el menor valor AIC=544.24 y el modelo ARIMA (2,0,2) porque presenta el menor error cuadrático medio (RMSE = 26.37). No obstante, el modelo ARIMA (2,0,2) arrojó que los parámetros no son significativos, por tanto, se descartó este modelo, mientras que en el modelo ARIMA (1,0,0) el parámetro y el intercepto son significativos; además, cumple los supuestos de estacionariedad, independencia y normalidad; sin embargo, el gráfico correspondiente al pronóstico no refleja el comportamiento de la serie original (Anexo 2).

**Tabla 19:** Modelo ARIMA propuestos.

Nombre	Modelos	AIC	RMSE
Modelo 1	AUTO.ARIMA (1,0,0)	544.24	27.04
Modelo 2	ARIMA (0,0,1)	558.19	30.65
Modelo 3	ARIMA (1,0,1)	545.62	26.88
Modelo 4	ARIMA (1,0,2)	546.14	26.51
Modelo 5	ARIMA (2,0,1)	546.33	26.57
Modelo 6	ARIMA (2,0,2)	547.56	26.37

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Por lo expuesto previamente, se proponen algunos modelos SARIMA para la ocupación de camas en el área de emergencia (tabla 20).

**Tabla 20:** Modelo SARIMA propuestos.

Nombre	Modelos	AIC	RMSE
Modelo 7	SARIMA (1,1,1) (0,0,1) [12]	540.22	27.69
Modelo 8	SARIMA (1,1,1) (1,0,0) [12]	540.21	27.69
Modelo 9	SARIMA (1,1,1) (1,0,1) [12]	541.80	27.04
Modelo 10	SARIMA (1,1,1) (0,0,2) [12]	541.97	27.52
Modelo 11	SARIMA (1,1,1) (1,0,2) [12]	539.44	22.55
Modelo 12	SARIMA (0,1,0) (0,0,1) [12]	541.55	29.10
Modelo 13	SARIMA (0,1,0) (1,0,0) [12]	541.55	29.06
Modelo 14	SARIMA (0,1,0) (1,0,1) [12]	543.41	29.04

Modelo 15	SARIMA (0,1,0) (1,0,2) [12]	540.92	25.66
Modelo 16	SARIMA (0,1,0) (0,0,2) [12]	541.66	27.81
Modelo 17	SARIMA (0,1,1) (0,0,1) [12]	539.42	28.04
Modelo 18	SARIMA (0,1,1) (0,0,2) [12]	540.80	27.61
Modelo 19	SARIMA (0,1,1) (1,0,2) [12]	542.22	26.64
Modelo 20	SARIMA (0,1,1) (1,0,0) [12]	539.40	28.03
Modelo 21	SARIMA (0,1,1) (1,0,1) [12]	541.39	28.03
Modelo 22	SARIMA (1,1,0) (0,0,1) [12]	539.68	28.11
Modelo 23	SARIMA (1,1,0) (0,0,2) [12]	540.91	27.60
Modelo 24	SARIMA (1,1,0) (1,0,0) [12]	539.64	28.09
Modelo 25	SARIMA (1,1,0) (1,0,1) [12]	541.95	28.19
Modelo 26	SARIMA (1,1,0) (1,0,2) [12]	540.80	25.94
Modelo 27	SARIMA (0,1,2) (0,0,1) [12]	541.13	27.96
Modelo 28	SARIMA (0,1,2) (0,0,2) [12]	542.67	27.62
Modelo 29	SARIMA (0,1,2) (1,0,2) [12]	544.10	26.43
Modelo 30	SARIMA (0,1,2) (1,0,0) [12]	541.12	27.95
Modelo 31	SARIMA (0,1,2) (1,0,1) [12]	543.11	27.95
Modelo 32	SARIMA (1,1,2) (0,0,1) [12]	540.58	26.84
Modelo 33	SARIMA (1,1,2) (0,0,2) [12]	542.27	26.66
Modelo 34	SARIMA (1,1,2) (1,0,0) [12]	540.57	26.83
Modelo 35	SARIMA (1,1,2) (1,0,1) [12]	542.02	26.09
Modelo 36	SARIMA (1,1,2) (1,0,2) [12]	541.07	23.39
Modelo 37	SARIMA (2,1,1) (0,0,1) [12]	540.37	26.79
Modelo 38	SARIMA (2,1,1) (0,0,2) [12]	542.09	26.63
Modelo 39	SARIMA (2,1,1) (1,0,0) [12]	540.36	26.78
Modelo 40	SARIMA (2,1,1) (1,0,1) [12]	542.36	26.78
Modelo 41	SARIMA (2,1,1) (1,0,2) [12]	541.02	23.29
Modelo 42	SARIMA (2,1,0) (0,0,1) [12]	541.68	28.10
Modelo 43	SARIMA (2,1,0) (0,0,2) [12]	542.90	27.60
Modelo 44	SARIMA (2,1,0) (1,0,0) [12]	541.64	28.09
Modelo 45	SARIMA (2,1,0) (1,0,1) [12]	543.62	28.08
Modelo 46	SARIMA (2,1,0) (1,0,2) [12]	542.79	25.88
Modelo 47	SARIMA (2,1,2) (0,0,1) [12]	541.35	26.52

Modelo 48	SARIMA (2,1,2) (0,0,2) [12]	543.14	26.43
Modelo 49	SARIMA (2,1,2) (1,0,0) [12]	541.34	26.52
Modelo 50	SARIMA (2,1,2) (1,0,1) [12]	543.34	26.52
Modelo 51	SARIMA (2,1,2) (1,0,2) [12]	542.5	23.58

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

De la tabla 20 se obtiene que el modelo SARIMA (1,1,1) (1,0,2) [12] es el que presenta los valores más pequeños de IAC = 539.44 y de RMSE = 22.55. Los demás modelos (17, 20, 22 y 24) con AIC muy cercano a 539.44 se probaron y los coeficientes estimados no resultaron significativos.

#### 4.4.2. Estimación de los parámetros del modelo

En esta etapa se estiman los parámetros para el modelo seleccionado usando el método de máxima verosimilitud (tabla 21).

**Tabla 21:** Estimación de parámetros para el modelo SARIMA (1, 1, 1) (1, 0, 2) [12].

<b>SARIMA (1,1,1) (1,0,2) [12]</b>					
	<b>ar1</b>	<b>ma1</b>	<b>sar1</b>	<b>sma1</b>	<b>sma2</b>
Coefficientes	0.7594	-1.0000	0.9634	-1.4128	0.5771
Error estándar	0.1033	0.0318	0.3827	1.3827	0.6593
$\sigma^2$	568.5	Probabilidad de registro =		-263.72	
AIC = 439.44	AICc = 541.15	BIC = 551.59			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-1.35696	22.5539	16.44221	-3.387311	11.4096	0.4091684

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

#### Significancia de los parámetros

Para comprobar si las estimaciones son significativas se considera como criterio:  $|z| > 1.96$  y  $p < 0.05$ . Para el modelo SARIMA (1,1,1) (1,0,2) [12] se observa que los parámetros ar1, ma1 y sra1 son significativos (tabla 22).

**Tabla 22:** Significancia de los parámetros del modelo SARIMA (1, 1, 1) (1, 0, 2) [12].

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	0.759401	0.103268	7.3537	1.928e-13 ***
ma1	-0.999998	0.031776	-31.4698	< 2.2e-16 ***
sra1	0.963401	0.382728	2.5172	0.01183 *
sma1	-1.412796	1.380215	-1.0236	0.30602
sma2	0.577060	0.659286	0.8753	0.38142

Códigos de significancia: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 '' 1

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

El modelo SARIMA (1,1,1) (1,0,2) [12] queda expresado de la siguiente manera:

$$Y_t = \varphi_1 Y_{t-1} + \Phi_1 Y_{t-12} - \theta_1 \varepsilon_{t-1} + \varepsilon_t$$

Por tanto, sustituyendo las estimaciones obtenidas en la tabla 21, la ecuación de pronóstico para la ocupación de camas en el área de emergencia viene dada por:

$$\Delta Y_t = 0.759401 Y_{t-1} + 0.963401 Y_{t-12} + 0.999998 \varepsilon_{t-1} + \varepsilon_t$$

donde:

$Y_t$ : Pronóstico mensual de la ocupación de camas.

$\varphi_1, \Phi_1, \theta_1$ : parámetro del modelo SARIMA.

$\varepsilon_t$ : error de ruido blanco.

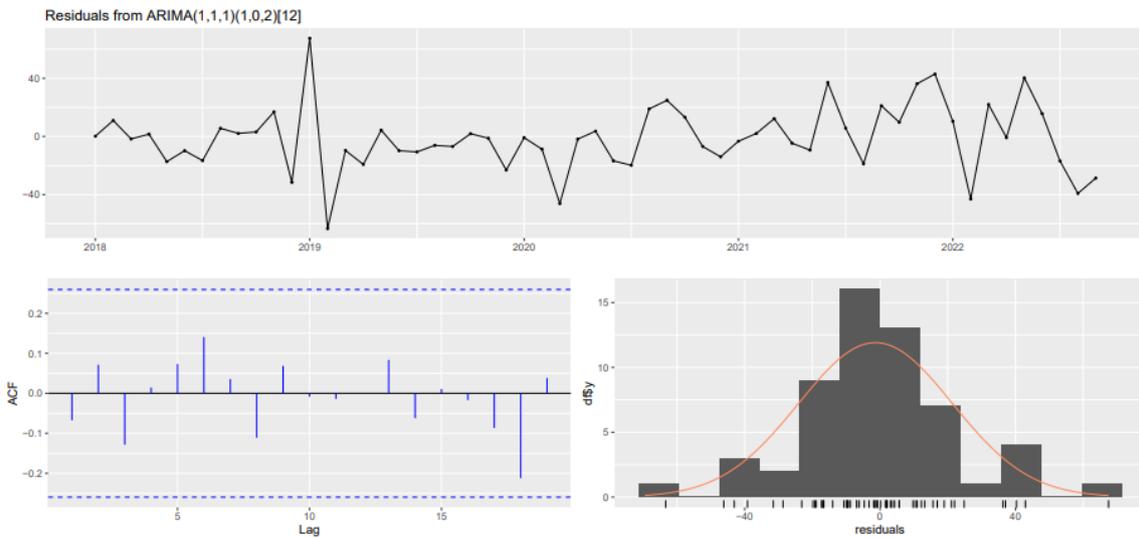
#### 4.4.3. Evaluación del modelo

En esta etapa se evalúan los residuos mediante un análisis gráfico con las pruebas de estacionariedad e independencia, así como con el test de normalidad.

##### *Análisis gráfico de los residuos*

En la figura 19 se presentan tres gráficos que permiten observar el comportamiento de los residuos. El primer gráfico corresponde a los residuos, de cuyo comportamiento se determinó que corresponden a ruido blanco; es decir tienen media cero e igual varianza. Por otro lado, se tiene la función de autocorrelación simple (ACF), la cual indica que los residuos son aleatorios ya que ningún rezago está por fuera de las bandas (intervalos de

confianza). Por último, el tercer gráfico indica que los residuos del modelo SARIMA  $(1,1,1)(1,0,3)[12]$  siguen aproximadamente una distribución normal.

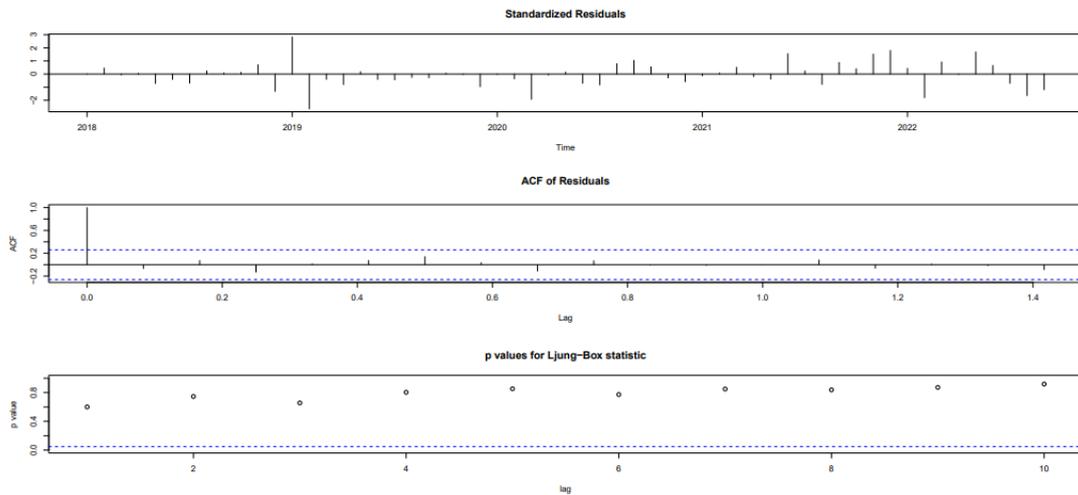


**Figura 19:** Análisis gráfico de los residuos del modelo SARIMA  $(1,1,1)(1,0,2)$ .

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Adicionalmente, se muestran los residuos estandarizados, el ACF de los residuos y los valores p del estadístico de Ljung-Box (figura 20). En cuanto a los residuos estandarizados se aprecia que son aleatorios. Así mismo, en el ACF todos los rezagos están dentro de las bandas azules y, por último, se observa que todos los valores p para el estadístico están por encima de 0.05, lo que permite corroborar lo mencionado previamente; es decir, que los residuos se comportan como ruido blanco. En general, se puede decir que el modelo SARIMA  $(1,1,1)(1,0,2)[12]$  se ajusta bien.



**Figura 20:** Diagnóstico de los residuos.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### *Prueba de estacionariedad de los residuos*

Para comprobar la estacionariedad de los residuos se aplicó la prueba de Dickey-Fuller.

Las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo SARIMA (1,1,1) (1,0,2)[12] no son estacionarios.

$H_1$ : los residuos del modelo SARIMA (1,1,1) (1,0,2)[12] son estacionarios.

#### Criterio de decisión

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

En la tabla 23 se muestran los resultados de la prueba observándose que el p valor es menor a 0.05, por tanto, se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA (1,1,1) (1,0,2)[12] son estacionarios.

**Tabla 23:** Test de Dickey-Fuller para probar estacionariedad de los residuos.

---

Datos: Modelo1\$residuals		
Dickey-Fuller = - 3.9027	Orden de retraso = 3	p_valor= 0.02017
Hipótesis alternativa: Estacionaria		

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### *Prueba de independencia de los residuos*

La independencia de los residuos se comprobó mediante el test de Ljung-Box con un nivel de significancia de 0.05. Para esta prueba, se contrastaron las siguientes hipótesis:

$H_0$ : los residuos del modelo SARIMA(1,1,1)(1,0,2)[12] son ruido blanco ( $\epsilon_t \sim RB(0, \sigma^2)$ )

$H_1$ : los residuos del modelo SARIMA (1,1,1) (1,0,2)[12] no son ruido blanco.

#### Criterio de decisión

p valor < 0.05 Rechazar  $H_0$ .

p valor  $\geq$  0.05 No Rechazar  $H_0$ .

En la tabla 24 se presentan los resultados de la prueba, observándose que el p valor (0.6011) es mayor que ( $\alpha=0.05$ ); no se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA (1,1,1) (1,0,2)[12] son independientes; es decir, se comportan como ruido blanco.

**Tabla 24:** Test de Ljung-Box para los residuos.

---

Datos: Residuos del modelo SARIMA (1,1,1) (1,0,2)[12]		
$Q^* = 4.5617$ ,	Grados de libertad = 6,	p_valor = 0.6011

---

Elaborado por: Gavilanes, 2022.  
Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### *Prueba de normalidad*

Para verificar la normalidad de los residuos se aplicó el test de Kolmogórov-Smirnov debido a que el número de registros es mayor a 50. En este caso, las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo SARIMA(1,1,1)(1,0,2)[12] siguen una distribución normal.

$H_1$ : los residuos del modelo SARIMA(1,1,1)(1,0,2)[12] no siguen una distribución normal.

### Criterio de decisión

p valor < 0.05 Rechazar Ho.

p valor  $\geq$  0.05 No Rechazar Ho.

En la tabla 25 se presentan los resultados de la prueba. Se observa que el p valor es 0.6183 mayor a ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo SARIMA(1,1,1)(1,0,2)[12] siguen una distribución normal.

**Tabla 25:** Prueba de normalidad para los residuos.

---

Datos: Residuos del modelo SARIMA(1,1,1)(1,0,2)[12]
D = 0.097277,      p_valor = 0.6183
Hipótesis alternativa: dos colas (bilateral)

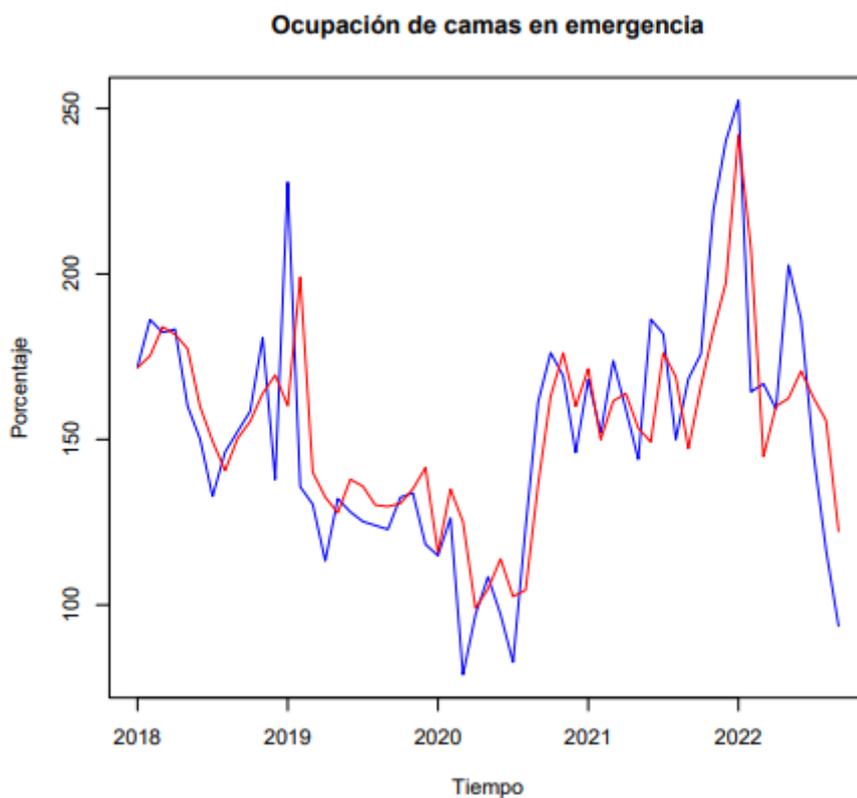
---

Elaborado por: Gavilanes, 2022.  
Fuente: Datos del área de emergencia del Hospital Básico Puyo.

La evaluación realizada a los residuos del modelo SARIMA(1,1,1)(1,0,2)[12] arrojó que estos cumplen con todos los supuestos mencionados previamente, por tanto, se pasa a la etapa de predicción (pronóstico).

#### **4.4.4. Predicción a través de la simulación del modelo desarrollado para el área de emergencia**

En esta etapa se procedió a comparar la serie original (línea azul) con los valores ajustados por el mejor modelo (línea roja) como se muestra en la figura 21. Se puede apreciar que el modelo SARIMA (1,1,1)(1,0,2)[12] se ajusta adecuadamente a la serie de tiempo de ocupación de camas en el área de hospitalización del Hospital Básico IESS Puyo.



**Figura 21:** Comparación de la serie original con los valores ajustados por el modelo SARIMA.  
 Elaborado por: Gavilanes, 2022.  
 Fuente: Datos del área de emergencia del Hospital Básico Puyo.

En la tabla 26 se presenta la comparación de los pronósticos para los dos grupos: entrenamiento y valores reales, con el fin de validar los pronósticos realizados con el modelo SARIMA (1, 1, 1) (1, 0, 2) [12]. Al comparar cada pronóstico con su valor real se observa que existe una diferencia significativa en los meses de noviembre (2021), diciembre (2021) y enero (2022) que puede estar asociada a factores externos. Sin embargo, se puede decir que el modelo permite hacer un pronóstico aceptable a largo plazo en un 88.61%.

**Tabla 26:** Comparación entre los datos de entrenamiento y testeo.

Meses	Testeo	Entrenamiento	Error
Julio (2021)	181.9	163.29	10.23
Agosto (2021)	150.0	166.99	-11.33
Septiembre (2021)	168.3	163.62	2.78
Octubre (2021)	175.8	166.57	5.25

Noviembre (2021)	219.2	173.28	20.94
Diciembre (2021)	240.3	160.45	33.23
Enero (2022)	252.4	180.16	28.62
Febrero (2022)	164.4	162.04	1.44
Marzo (2022)	166.8	146.59	12.12
<b>PROMEDIO</b>	191.01	164.78	

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

En la tabla 27 se presentan los pronósticos obtenidos con el modelo SARIMA(1,1,1)(1,0,2)[12] así como los intervalos de confianza del 80% y 95%. En esta investigación se considera el intervalo del 95%.

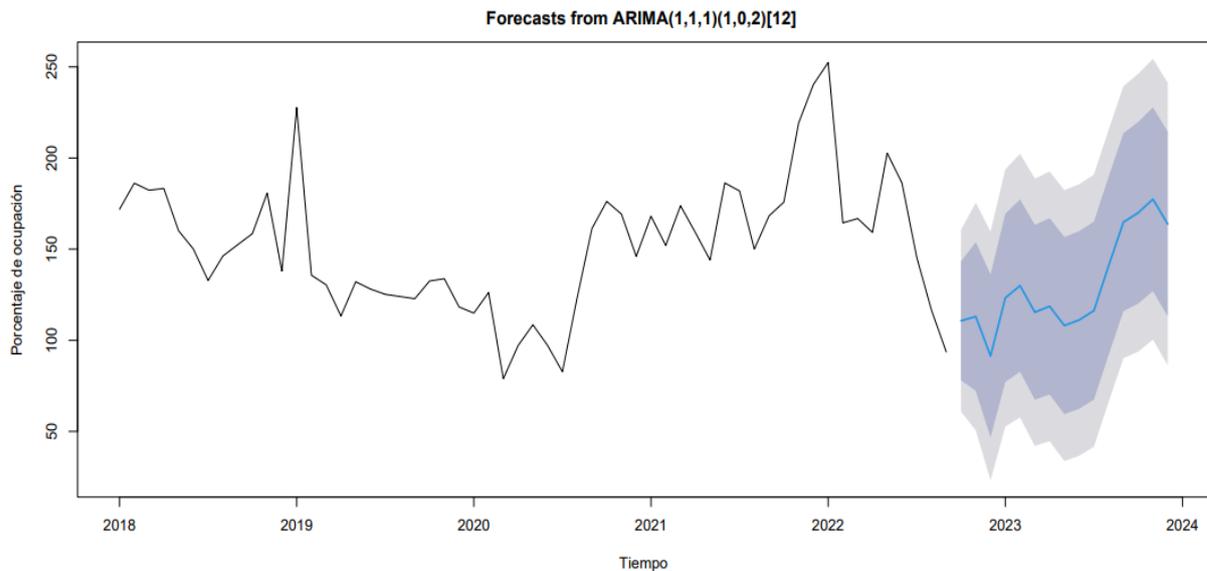
**Tabla 27:** Pronóstico del modelo SARIMA(1,1,1)(1,0,2)[12]

Meses	Pronóstico (%)	Límite inferior 80%	Límite superior 80%	Límite inferior 95%	Límite superior 95%
Enero	123.22	77.13	169.31	52.73	193.71
Febrero	130.01	82.74	177.28	57.72	202.30
Marzo	115.35	67.40	163.30	42.02	188.68
Abril	118.63	70.28	166.97	44.68	192.57
Mayo	108.07	59.49	156.65	33.77	182.37
Junio	111.11	62.40	159.82	36.61	185.61
Julio	116.26	67.48	165.03	41.66	190.86
Agosto	140.89	92.10	189.69	66.27	215.52
Septiembre	164.80	116.02	213.57	90.20	239.39
Octubre	169.96	120.16	219.76	93.79	246.13
Noviembre	177.40	127.04	227.75	100.39	254.40
Diciembre	163.76	113.14	214.38	86.35	241.18

Elaborado por: Gavilanes, 2022

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Las proyecciones para la ocupación de camas en el área de emergencia de acuerdo al modelo SARIMA se presentan en la figura 22. La línea de color negro corresponde a la serie de tiempo bajo estudio y la línea azul representa la media del pronóstico para el porcentaje de ocupación de camas por mes. Además, se tiene el color gris oscuro y gris claro que se refieren a los intervalos de confianza del 80% y 95%, respectivamente. Se observa que a comienzos de año el porcentaje de ocupación aumenta. Posteriormente, disminuye, y a partir del mes de junio aumenta, nuevamente llegando a su valor más alto en el mes de noviembre.



**Figura 22:** Pronóstico para la ocupación de camas para el año 2023.

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencias del Hospital Básico Puyo.

#### 4.5. DISCUSIÓN DE RESULTADOS

La caracterización de modelos estadísticos en función de los datos proporcionados por el Departamento de Estadística del Hospital Básico Puyo del IESS muestra que los modelos prospectivos adecuados para modelar el porcentaje de ocupación de camas en el Hospital Básico IESS Puyo en las áreas de hospitalización y emergencia son los modelos SARIMA.

Los modelos estadísticos prospectivos construidos para determinar la ocupación de camas en las áreas de hospitalización y emergencia son: SARIMA(1,1,1)(1,0,3)[12] y SARIMA(1,1,1)(1,0,2)[12], respectivamente.

Como parte del cumplimiento del objetivo 3, la simulación del modelo prospectivo para el área de hospitalización arroja que las proyecciones o pronósticos para el año 2023 presenta un aumento desde enero hasta mayo, siendo para este último mes donde se pronostica el porcentaje de ocupación de camas más alto del año, correspondiente al 80.89%. A partir del mes de junio disminuye el porcentaje de ocupación de camas alcanzando en octubre el menor porcentaje el cual es de 60.11%. Para los dos últimos meses del año se aprecia nuevamente un aumento, pasando de 60.11% a 64.71% y 64.45%, en noviembre y diciembre, respectivamente.

En cuanto al área de emergencia las proyecciones arrojaron un aumento en los primeros meses del 2023. Para el mes de mayo se tiene el porcentaje más bajo de todo el año, de 108.07%. Posteriormente desde el mes de junio hasta noviembre se observa un incremento mensual, siendo este último mes para el que se pronostica el mayor porcentaje de ocupación, de 177.40%.

En ambas áreas, hospitalización y emergencia, el pronóstico indica que a comienzos del año 2023 hay un aumento en el porcentaje de ocupación de camas, mismo que puede ser atribuido al cambio climático en los últimos meses del año anterior; el cual es un factor determinante en el aumento de casos de influenza, gripe, afecciones respiratorias.

Las pruebas de evaluación del modelo para determinar la significancia de los parámetros mediante el método de verosimilitud, así como el diagnóstico realizado a los residuos muestran que el modelo es bueno, se ajusta adecuadamente. Al comparar los modelos SARIMA con la serie histórica de porcentaje de ocupación de camas se observa que las proyecciones son semejantes. La eficacia del modelo del área de emergencias (88.61%) es más alta en comparación con la del modelo del área de hospitalización (87.16%).

## CAPÍTULO V

### CONCLUSIONES Y RECOMENDACIONES

#### 5.1. CONCLUSIONES

- La caracterización de modelos estadísticos se llevó a cabo mediante la metodología Box-Jenkins, implementado modelos ARIMA y SARIMA con el fin de determinar cuál de ellos describe mejor al porcentaje de ocupación de camas del Hospital Básico Puyo del IESS. Los análisis arrojaron que los modelos SARIMA son los que mejor se ajustan para los datos bajo estudio.
- Los modelos estadísticos prospectivos se construyeron por área. El modelo que se ajusta al porcentaje de ocupación de camas para el área de hospitalización es un SARIMA (1,1,1) (1,0,3) [12] cuya estimación arrojó como ecuación de pronóstico:  $\Delta Y_t = -0.79034 Y_{t-1} + \epsilon_t$ . En cuanto al área de emergencia, el modelo es un SARIMA (1,1,1) (1,0,2) [12], cuya ecuación de pronóstico es:  $\Delta Y_t = 0.759401 Y_{t-1} + 0.963401 Y_{t-12} + 0.999998 \epsilon_{t-1} + \epsilon_t$ . Ambos modelos al ser validados tomando en cuenta un conjunto de datos de testeo, es decir, datos reales y otro grupo para entrenamiento, se observó que el porcentaje de error es bajo, lo que permitió comprobar que los modelos son buenos.
- La simulación con los modelos estadísticos prospectivos propuestos arrojó que el pronóstico para el 2023 en el área de hospitalización muestra que para los primeros meses del año el porcentaje de ocupación aumenta, posteriormente comienza a disminuir a partir del mes de junio. Su valor más bajo es en el mes de enero (59.77%) y el más alto se refleja para mayo (80.89%), mientras que en el área de emergencias los primeros meses aumenta y disminuye en muy poco porcentaje; sin embargo, a partir del mes de junio comienza a aumentar, llegando a su valor más alto en el mes de noviembre (177.40%). Los pronósticos arrojados por los modelos son buenos, siguen el comportamiento de la serie original.
- De acuerdo con los resultados emitidos por el modelo estadístico, se encontró que la ocupación de camas tanto en el área de hospitalización como emergencias no tuvo gran demanda al inicio de la pandemia, porque es un hospital básico, además que el

virus del COVID-19 causó mucho temor entre los pacientes, lo que provocó que el porcentaje de ocupación hospitalaria sea bajo. En virtud de aquello, la administración hospitalaria determinó realizar la atención por teléfono y que la medicación sea entregada en casa. En éste contexto, cuando la población empezó a comprender la gravedad de la pandemia, el número de hospitalizaciones se incrementó, especialmente en el área de emergencias.

- La eficacia del modelo se comprobó comparando la serie original del porcentaje de ocupación de camas con los pronósticos arrojados por ambos modelos y se observó que son semejantes; por lo tanto, los modelos prospectivos encontrados permiten tener un pronóstico efectivo a mediano plazo. La eficacia de los modelos del área de emergencia y hospitalización es de 88.61% y 87.16%, respectivamente. Se observó que el porcentaje de eficacia es bueno, más del 80% de las veces son eficientes los modelos. Existe un margen de error del 20%, donde no logran acoplarse a los valores originales.

## 5.2. RECOMENDACIONES

- Sería conveniente realizar el modelamiento de la ocupación de camas por especialidad ya que al revisar los archivos suministrados por el Departamento de Estadística del Hospital se aprecia que el egreso de pacientes en el área de hospitalización es más frecuente en las especialidades de medicina interna, cirugía, pediatría, traumatología y obstetricia, mientras que para el área de emergencias se observó que en su mayoría los pacientes que egresan son adultos.
- Construir modelos estadísticos prospectivos más adelante cuando la pandemia por COVID-19 y sus efectos hayan culminado para determinar los modelos prospectivos para la ocupación de camas por área y por especialidad para que fenómenos atípicos como la pandemia no alteren el comportamiento del normal funcionamiento del hospital.
- Debido al gran impacto que hoy tiene el uso de la Inteligencia Artificial en aplicaciones y procesos investigativos, a futuro se podría utilizar para pronosticar el comportamiento de la ocupación de camas del hospital, con el fin de comparar los resultados que se obtengan con los que se obtuvieron en el presente trabajo.

### 5.3. Referencias

- [1] E. Quesada. *Cantidad, Uso y Gestión de las Camas Hospitalarias. tendencias en el mundo y situación en Mendoza* . 2011. [en línea] Disponible en: <https://isg.org.ar/wp-content/uploads/2011/12/Gestion-camas-hospitalarias-ISG.pdf>
- [2] T. Ceballos-Acevedo. P.A. Velásquez-Restrepo. JS.Jaén-Posada *Duración de la estancia hospitalaria. Metodologías para su intervención*. Rev. Gerenc. Polít. Salud. 2014; 13(27): 274-295. [en línea] Disponible en: <http://dx.doi.org/10.11144/Javeriana.rgyps13-27.dehm>
- [3] J. Barado. *Un médico crea un modelo matemático que predice la ocupación de camas en UCI. Pamplona*. Revista Sanitaria. 2015. [en línea] Disponible en: <https://www.redaccionmedica.com/secciones/gestion/un-medico-crea-un-modelo-matematico-que-predice-la-ocupacion-de-camas-en-uci-85169>
- [4] M. Capistran. A. Capella, J. Christen. *Modelos matemáticos predictivos y pronósticos de demanda hospitalaria por brotes epidémicos de COVID-19*. Revista Ciencia. Vol. 71. N° 3. 2020. [en línea]. Disponible en: <https://www.revistaciencia.amc.edu.mx/index.php/vol-71-numero-3-e/813-el-modelado-de-la-pandemia-de-covid-19-es-un-reto-en-distintas-areas-sanitarias-y-cientificas-el-desarrollo-de-modelos-matematicos-debe-estar-basado-en-preguntas-concretas-que-consideren-explicitamente-sus-alcances-limitaciones-y-la-incertidumbre-asociada-al-fenomeno-presentamos-un-modelo-para-hacer-pronosticos-probabilisticos-de-la-presion-hospitalaria-con-base-en-casos-detec-tados-y-decesos>
- [5] Fundación DESQBRE. *Desarrollan un modelo predictivo de ocupación de camas en las UCI de los hospitales andaluces*. Universidad de Cádiz. 2020. [en línea]. Disponible en: <https://fundaciondescubre.es/noticias/desarrollan-un-modelo-predictivo-de-ocupacion-de-camas-en-las-uci-de-los-hospitales-andaluces/>
- [6] Centro Cochrane Iberoamericano. *¿Qué ofrecen los modelos matemáticos para estimar la necesidad de hospitalización y/o tratamiento en las unidades de cuidados intensivos debido a la COVID-19?* 2020. [en línea]. Disponible en: <https://es.cochrane.org/es/que-ofrecen-los-modelos-matematicos-para-estimar-la-necesidad-de-hospitalizacion-yo-tratamiento-en>

- [7] F. Mallor. *Un modelo para predecir cuántas camas UCI harán falta durante cada oleada*. Universidad Pública de Navarra. 2021. [en línea] Disponible en: <https://www.diariodenavarra.es/noticias/vivir/ciencia/2021/04/05/un-modelo-para-predecir-cuantas-camas-uci-haran-falta-durante-cada-oleada-722470-3241.html>
- [8] M. Cabanilla. “*Diseño de un modelo administrativo para optimizar la gestión de camas en los hospitales públicos de la ciudad de Machala*”. Revista Universidad y Sociedad vol.13 no.2. 2021 [en línea]. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S2218-36202021000200489](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2218-36202021000200489)
- [9] M. Morera. “*Gestión de estancias y ocupación de camas de hospitales públicos de Costa Rica*”. 2014. Acta Médica Costarricense, vol. 56, núm. 3, [en línea]. Disponible en: <https://www.redalyc.org/pdf/434/43432149004.pdf>
- [10] V. Gonzáles. E. Hernández. “*Indicadores de gestión hospitalaria*”. Revista de Ciencias Sociales v.13 n.3. 2007. [en línea]. Disponible en: [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S1315-95182007000300006](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S1315-95182007000300006)
- [11] OSSO. “*Análisis y Modelos estadísticos*”. 2003. [en línea]. Disponible en: <https://www.osso.org.co/docu/tesis/2003/evaluacion/analisis.pdf>
- [12] J. López, “*Estadística descriptiva*”, 2019. [en línea]. Economipedia.com Disponible en: <https://economipedia.com/definiciones/estadistica-descriptiva.html>
- [13] M. Bartlett. (2010). Modelización de Series Univariantes: (S)ARIMA. Disponible en: [https://bookdown.org/victor\\_morales/SeriesdeTiempo/modelizaci%C3%B3n-de-series-univariantes-sarima.html](https://bookdown.org/victor_morales/SeriesdeTiempo/modelizaci%C3%B3n-de-series-univariantes-sarima.html)
- [14] D. Gujarati & D. Porter. (2009). *Econometría*. 5ta ed. Ed. Mc Graw Hill. México D.F. p. 737-778
- [15] V. Oñate. (2022). Series de tiempo (Componentes de una serie temporal). Disponible en: [http://www5.uva.es/estadmed/datos/series/series1.htm#:~:text=Se%20denomina%20tendencia%20de%20una,representar%20la%20tendencia%20\(creciente\).](http://www5.uva.es/estadmed/datos/series/series1.htm#:~:text=Se%20denomina%20tendencia%20de%20una,representar%20la%20tendencia%20(creciente).)

- [16] RStudio. (2022). Series de Tiempo: Estacionariedad. Disponible en: <https://rpubs.com/Arthurus/492144#:~:text=%C2%BFPor%20qu%C3%A9%20es%20importante%20la,a%20la%20hora%20de%20predecir>.
- [17] N. Chávez. (1997). Modelos ARIMA, Disponible en: [http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S2077-33231997000100005#:~:text=Los%20modelos%20SARIMA%20captan%20el,componete%20regular%20o%20no%20estacional](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2077-33231997000100005#:~:text=Los%20modelos%20SARIMA%20captan%20el,componete%20regular%20o%20no%20estacional). Párr. 27
- [18] Trader Studio. (2021). *Modelo Box-Jenkins*. [en línea]. Disponible en: <https://traders.studio/modelo-box-jenkins/> párr. 1,3,7
- [19] J. Campos, G. Cárdenas, D. Cañadas et al. *Instituto Ecuatoriano de Seguridad Social. Coordinación Provincial de prestaciones de Salud Tungurahua Hospital Básico del IESS Puyo*. 2021 [en línea]. Disponible en: [www.iees.gob.ec](http://www.iees.gob.ec)
- [20] E. Quesada. *Cantidad, Uso y Gestión de las Camas Hospitalarias. tendencias en el mundo y situación en Mendoza*. 2011 [en línea]. Disponible en: <https://isg.org.ar/wp-content/uploads/2011/12/Gestion-camas-hospitalarias-ISG.pdf>
- [21] IESS. (2021). *Actualización del Plan Médico-Funcional Hospital Básico el Puyo*.
- [22] Hurtado, J. (2008). *Metodología de la investigación. Guía para la comprensión holística de la ciencia*. Ediciones Quirón S.A.
- [23] Hernández R., Fernández C. y Baptista P. (2010). *Metodología de la investigación*. (Quinta Edición). México: McGraw-Hill. p. 80, 83, 84
- [24] Bernal, C. (2010). *Metodología de la investigación, administración, economía, humanidades y ciencias sociales*. Pearson Educación: Bogotá D.C, Colombia. p. 120
- [25] Mousalli-Kayat, G. (2015). *Métodos y Diseños de Investigación Cuantitativa*. Mérida. p. 26
- [26] Rodríguez, L. (2007). *Probabilidad y estadística básica para ingenieros*. Escuela Superior Politécnica del Litoral, Instituto de Ciencias Matemáticas. Guayaquil, Ecuador. p. 8.

[27] Chatfield, C. (1989). *The Analysis of time Series: An Introduction*. 4<sup>a</sup> ed. Chapman & Hall.

## 5.4. ANEXOS

### Anexo 1. Metodología Box-Jenkins aplicada a los modelos ARIMA (0, 1, 1) y ARIMA (1, 1, 1) correspondientes al área de hospitalización.

#### Estimación de los parámetros del modelo

En esta etapa se estiman los parámetros del modelo usando el método de máxima verosimilitud. En la tabla 28, se presentan los parámetros para el modelo ARIMA (1,1,0).

**Tabla 28:** Estimación de parámetros del modelo ARIMA (1,1,0).

<b>ARIMA (1,1,0)</b>					
<b>ar1</b>					
Coefficientes	-0.1923				
Error estándar	0.1299				
$\sigma^2$	159.9	Probabilidad de registro =	-221.07		
AIC = 446.14	AICc = 446.36	BIC = 450.19			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-0.6608326	12.42277	9.365684	-3.324172	14.54863	0.4577658

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

En la tabla 29 se presentan los parámetros para el modelo ARIMA (1,1,1).

**Tabla 29:** Estimación de los parámetros del modelo ARIMA (1,1,1).

<b>ARIMA (1,1,1)</b>					
	<b>ar1</b>	<b>ma1</b>			
Coefficientes	-0.7593	0.6108			
Error estándar	0.3465	0.4295			
$\sigma^2$	160.4	Probabilidad de registro =	-220.65		
AIC = 447.3	AICc = 447.76	BIC = 453.38			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-0.5981806	12.32569	9.231517	-2.964201	14.05218	0.4512081

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### Significancia de los parámetros

Para comprobar si las estimaciones son significativas se considera que el valor absoluto de z debe ser mayor a 1.96 y, la probabilidad debe ser inferior a 0.05. Para el modelo ARIMA (1,1,0) se observa que el valor de z del parámetro ar1 es inferior a 1.96 y la probabilidad superior a 0.05, por tanto, el parámetro no es significativo (tabla 28), descartándose dicho modelo.

En cuanto al modelo ARIMA (1,1,1), se tiene que el parámetro ar1 es significativo, ya que el valor z es superior al valor crítico de referencia y la probabilidad es menor a 0.05 (tabla 30).

**Tabla 30:** Significancia de los parámetros del modelo ARIMA (1,1,0).

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	-0.19235	0.12987	-1.4811	0.1386

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

**Tabla 31:** Significancia de los parámetros del modelo ARIMA (1,1,1).

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	-0.75927	0.34647	-2.1914	0.02842 *
ma1	0.61083	0.42952	1.4221	0.15500

Códigos de significancia: 0 '\*\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 '' 1

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

Por tanto, el modelo ARIMA (1,1,1) se expresa como sigue:

$$Y_t = \varphi_1 Y_{t-1} + \epsilon_t$$

Tomando en cuenta las estimaciones de la tabla 29, la ecuación de pronóstico para la ocupación de camas en el área de hospitalización queda de la siguiente manera:

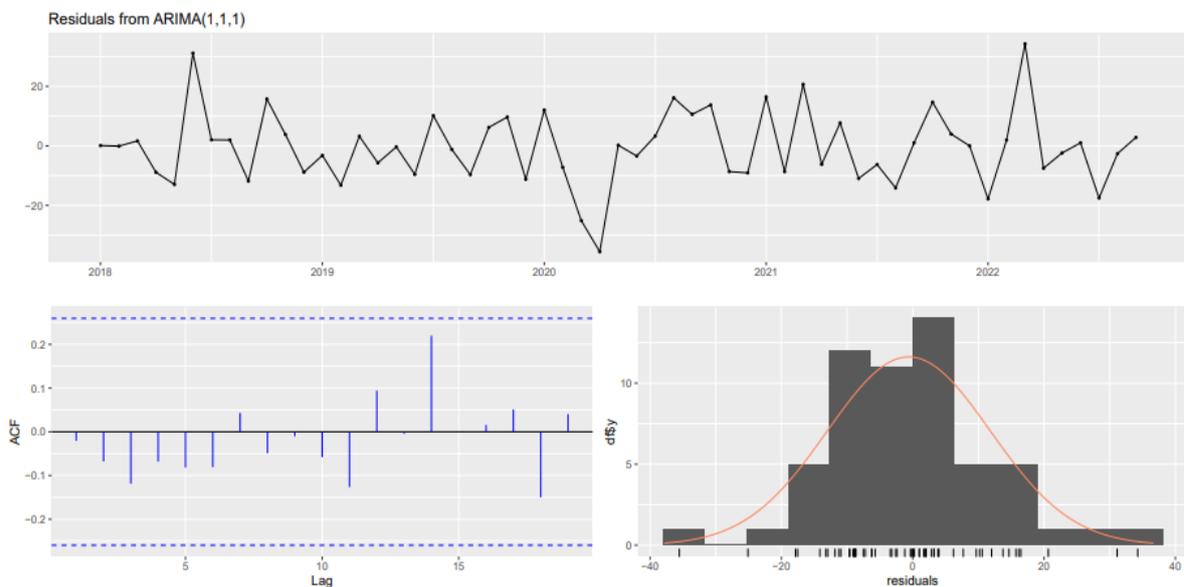
$$\Delta Y_t = -0.75927 Y_{t-1} + \epsilon_t$$

### Evaluación del modelo

En esta etapa se evalúan los residuos mediante un análisis gráfico con las pruebas de estacionariedad e independencia, así como con el test de normalidad.

### Análisis gráfico de los residuos

En la figura 23 se presentan tres gráficos que permiten observar el comportamiento de los residuos. El primer gráfico corresponde a los residuos, indicándose que son ruido blanco, es decir, que éstos son independientes e idénticamente distribuidos a lo largo del tiempo. Por otro lado, se tiene la función de autocorrelación simple (ACF), la cual indica que los residuos son aleatorios ya que ningún rezago está por fuera de las bandas (intervalos de confianza). Por último, el tercer gráfico es el histograma con la curva de la distribución normal, la cual indica que los residuos del modelo ARIMA (1, 1, 1) siguen aproximadamente una distribución normal.

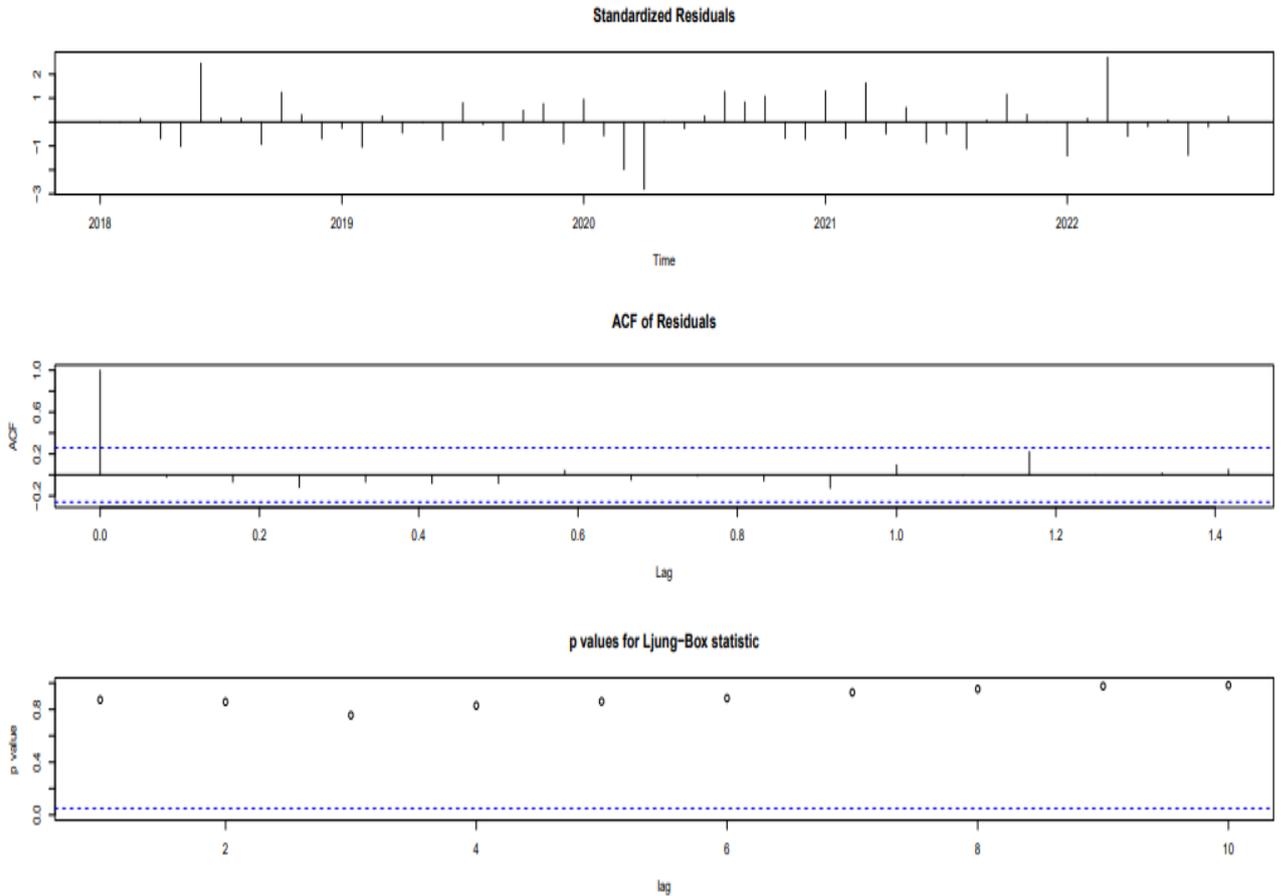


**Figura 23:** Análisis de los residuos del modelo ARIMA (1,1,1).

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

Para complementar el análisis gráfico, en la figura 24 se muestran tres gráficos. El primero de ellos muestra los residuos estandarizados, observándose que estos no exhiben un patrón (son aleatorios), por lo que constituyen ruido blanco, es decir, no existe correlación entre los valores a través del tiempo. El segundo gráfico muestra el ACF, apreciándose que ningún rezago es significativo (todos se encuentran dentro de los intervalos de confianza). En el tercer gráfico se reflejan los valores p del estadístico de Ljung-Box, observándose que todos los residuos están por encima del nivel de significancia establecido de 0.05, corroborando nuevamente que estos son ruido blanco.



**Figura 24:** Diagnóstico de los residuos del modelo ARIMA (1,1,1).  
 Elaborado por: Gavilanes, 2022.  
 Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

*Prueba de estacionariedad de los residuos*

Para comprobar la estacionariedad de los residuos se aplicó la prueba de Dickey-Fuller. Las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo ARIMA (1,1,1) son estacionarios.

$H_1$ : los residuos del modelo ARIMA (1,1,1) no son estacionarios.

Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 32 se presentan los resultados de la prueba, observándose que el p valor es menor al nivel de significancia ( $\alpha=0.05$ ), por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1, 1, 1) son estacionarios.

**Tabla 32:** Test de Dickey-Fuller para los residuos del modelo ARIMA (1,1,1).

---

**Test de Dickey- Fuller aumentada**

---

Datos: Modelo4\$residuals

Dickey-Fuller = - 4.2037                      Orden de retraso = 3                      p\_valor = 0.01

Hipótesis alternativa: Estacionaria

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

*Prueba de independencia de los residuos*

La independencia de los residuos se comprobó mediante el test de Ljung-Box, con un nivel de significancia de 0.05. Para esta prueba, se contrastaron las siguientes hipótesis:

$H_0$ : los residuos del modelo ARIMA (1,1,1) son ruido blanco ( $\epsilon_t \sim RB(0, \sigma^2)$ )

$H_1$ : los residuos del modelo ARIMA (1,1,1) no son ruido blanco.

Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 33 se presentan los resultados de la prueba, observándose que el p\_value es de 0.8732 siendo mayor al nivel de significancia ( $\alpha=0.05$ ), por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1, 1, 1) son independientes, es decir, se comportan como ruido blanco.

**Tabla 33:** Test de Ljung-Box para los residuos del modelo ARIMA (1,1,1).

---

**Test Ljung-Box**

---

Datos: Residuos del modelo ARIMA (1, 1, 1)

X-cuadrado = 0.025485,                      Grados de libertad = 1,                      p\_valor = 0.8732

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

### *Prueba de normalidad*

Para verificar la normalidad de los residuos se aplicó el test de Kolmogórov-Smirnov debido a que el número de registros es mayor a 50. En este caso, las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo ARIMA (1,1,1) siguen una distribución normal.

$H_1$ : los residuos del modelo ARIMA (1,1,1) no siguen una distribución normal.

#### Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 34 se presentan los resultados de la prueba. Se observa que el p valor es 0.4533 siendo mayor al nivel de significancia ( $\alpha=0.05$ ), por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1, 1, 1) siguen una distribución normal.

**Tabla 3428:** Prueba de normalidad para los residuos del modelo ARIMA (1,1,1).

---

#### **Test de Kolmogorov-Smirnov**

---

Datos: Residuos del modelo ARIMA (1, 1, 1)

D = 0.11083,      p\_valor = 0.4533

Hipótesis alternativa: dos colas (bilateral)

---

Elaborado por: Gavilanes, 2022.

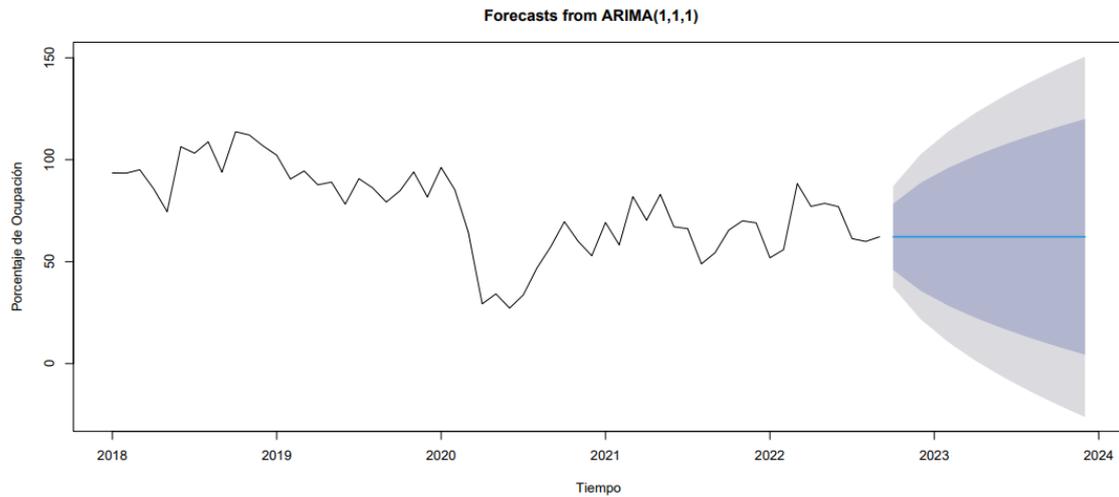
Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

La evaluación realizada a los residuos del modelo ARIMA (1, 1, 1) arrojó que estos cumplen con todos los supuestos mencionados previamente, por tanto, se pasa a la etapa de predicción (pronóstico).

#### **Predicción en base al modelo**

En esta etapa se procedió a realizar el pronóstico para el período enero 2023 – diciembre 2023, observándose que el modelo ARIMA (1,1,1) no pronostica bien, no sigue el comportamiento adecuado, en comparación con la serie original (figura 25). Por tanto, para obtener un buen pronóstico se probaron todos los modelos propuestos en la

metodología en el apartado correspondiente al área de hospitalización; con el fin de seleccionar aquel que mejor se ajuste a la serie original.



**Figura 25:** Pronóstico con el modelo ARIMA (1,1,1).

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de hospitalización del Hospital Básico Puyo.

**Anexo 2. Metodología Box-Jenkins aplicada a los modelos ARIMA (0, 1, 1) y ARIMA (1, 1, 1) correspondientes al área de emergencia.**

**Estimación de los parámetros del modelo**

En esta etapa se estiman los parámetros de los modelos usando el método de máxima verosimilitud. En la tabla 35 se presentan los parámetros para el modelo ARIMA (1,0,0).

**Tabla 3529:** Estimación de los parámetros del modelo ARIMA (1,0,0).

<b>ARIMA (1,0,0)</b>					
<b>ar1</b>					
Coefficientes	0.6724				
Error estándar	0.0988				
$\sigma^2$	757.5	Probabilidad de registro =	-269.12		
AIC = 544.24	AICc = 544.69	BIC = 550.37			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-0.3490108	27.03596	20.45228	-3.548636	14.05023	0.5089602

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

En la tabla 36 se presentan los parámetros para el modelo ARIMA (2,0,2).

**Tabla 36:** Estimación de los parámetros del modelo ARIMA (2,0,2).

<b>ARIMA (2,0,2)</b>					
	<b>ar1</b>	<b>ar2</b>	<b>ma1</b>	<b>ma2</b>	
Coefficientes	0.1140	0.3132	0.5255	0.2169	
Error estándar	0.3832	0.3424	0.3778	0.2218	
$\sigma^2$	762.5	Probabilidad de registro =	-267.78		
AIC = 547.56	AICc = 549.24	BIC = 559.82			
Medidas de error en el conjunto de entrenamiento					
ME	RMSE	MAE	MPE	MAPE	MASE
-0.3135815	26.37395	20.15394	-3.395373	13.88642	0.5015359

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### Significancia de los parámetros

Para comprobar si las estimaciones son significativas tomando en cuenta un nivel de significancia de 0.05, el valor absoluto de z debe ser mayor a 1.96 y la probabilidad debe ser inferior a 0.05. En el modelo ARIMA (1,0,0) los parámetros son significativos (tabla 36). Por su parte, los parámetros del modelo ARIMA (2,0,2) no son significativos, se descarta ese modelo (tabla 37).

**Tabla 307:** Significancia de los parámetros del modelo ARIMA (1,0,0).

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	-0.19235	0.12987	6.8062	1.002 e-11 ***
intercept	150.54761	10.57059	14.2421	< 2.2 e-16 ***
Códigos de significancia: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 '' 1				

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

**Tabla 318:** Significancia de los parámetros del modelo ARIMA (2,0,2).

Parámetros	Estimación	Error Std.	Valor z	Prob. (> z )
ar1	0.11399	0.38324	0.2974	0.7661
ar2	0.31321	0.34238	0.9148	0.3603
ma1	0.52545	0.37782	1.3907	0.1643
ma2	0.21693	0.22183	0.9779	0.3281
intercept	150.58500	10.31740	14.5953	< 2.2 e-16 ***
Códigos de significancia: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 '' 1				

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Tomando en cuenta las estimaciones de la tabla 36, la ecuación de pronóstico para la ocupación de camas en el área de emergencia queda de la siguiente manera:

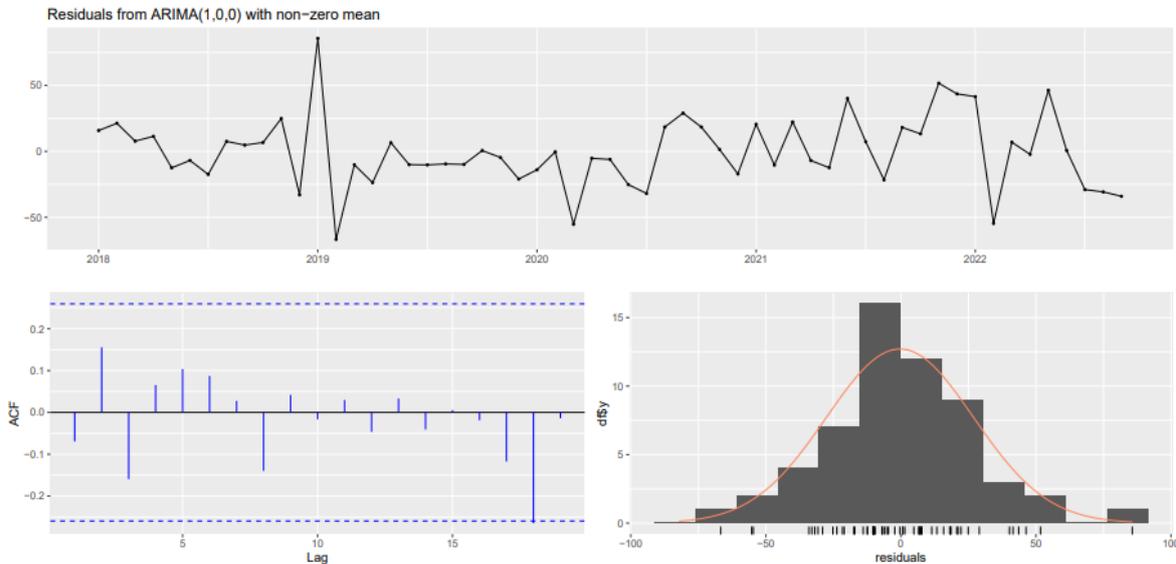
$$\Delta Y_t = 150.54761 - 0.19235Y_{t-1} + \epsilon_t$$

## Evaluación del modelo

En esta etapa se evalúan los residuos mediante un análisis gráfico, las pruebas de estacionariedad e independencia, así como con el test de normalidad.

### *Análisis gráfico de los residuos*

En la figura 26 se presentan tres gráficos que permiten observar el comportamiento de los residuos. El primer gráfico corresponde a los residuos, por el comportamiento que se observa son ruido blanco; es decir, no existe correlación entre los valores a través del tiempo. Por otro lado, se tiene la función de autocorrelación simple (ACF), la cual indica que los residuos son aleatorios debido a que todos los rezagos están dentro de las bandas (intervalos de confianza). Por último, el tercer gráfico es el histograma con la curva de la distribución normal, lo que indica que los residuos del modelo ARIMA (1,0,0) siguen aproximadamente una distribución normal.



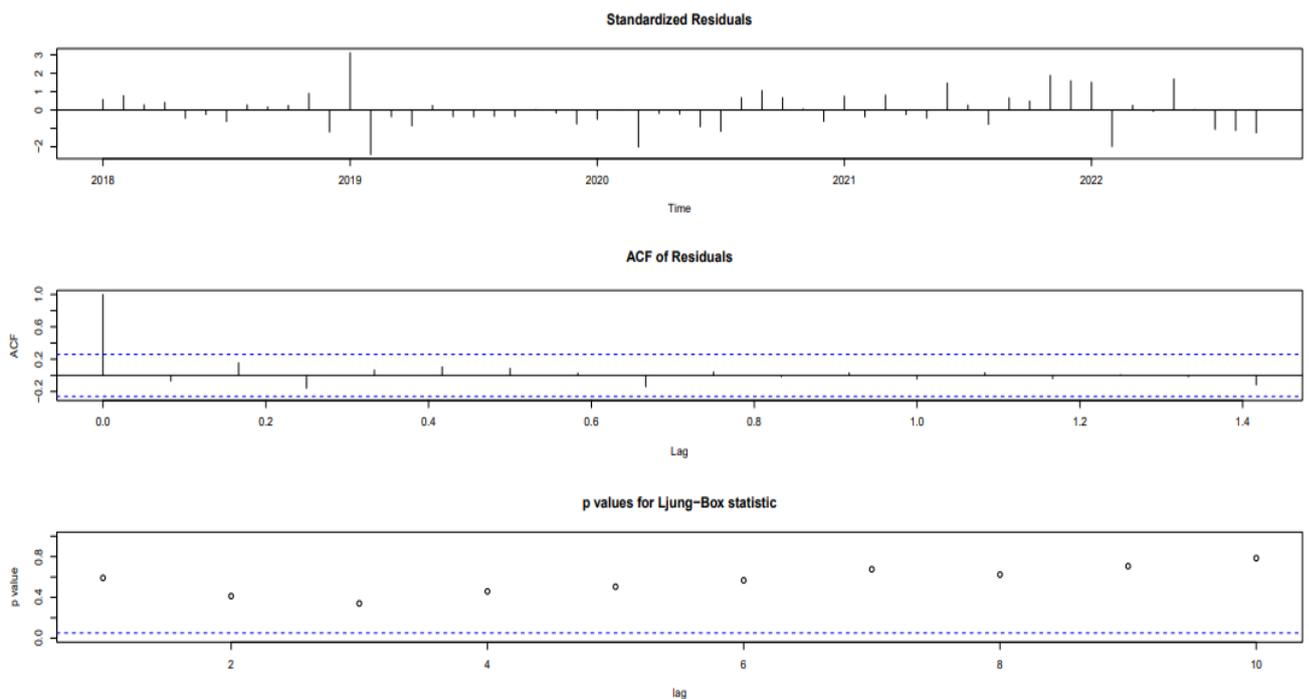
**Figura 26:** Análisis de los residuos del modelo ARIMA (1,0,0).

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

Para complementar el análisis gráfico, en la figura 27, se muestran tres gráficos. El primero de ellos muestra los residuos estandarizados, observándose que estos no exhiben un patrón (son aleatorios), por lo que constituyen ruido blanco, no existe correlación entre los valores a través del tiempo. El segundo gráfico muestra el ACF, apreciándose que

ningún rezago es significativo. En el tercer gráfico se reflejan los valores p del estadístico de Ljung-Box, observándose que no todos los residuos están por encima del nivel de significancia establecido de 0.05; sin embargo, la prueba de independencia del test arroja un p valor de 0.7791, lo cual indica que no se rechaza la hipótesis nula y se concluye que los residuos son ruido blanco.



**Figura 27:** Diagnóstico de los residuos del modelo ARIMA (1,0,0).

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

### *Prueba de independencia de los residuos*

La independencia de los residuos se comprobó mediante el test de Ljung-Box, con un nivel de significancia de 0.05. Para esta prueba se contrastaron las siguientes hipótesis:

$H_0$ : los residuos del modelo ARIMA (1,0,0) son ruido blanco ( $\epsilon_t \sim RB(0, \sigma^2)$ )

$H_1$ : los residuos del modelo ARIMA (1,0,0) no son ruido blanco.

### Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 39 se presentan los resultados de la prueba, observándose que el p valor es de 0.7791 el cual es mayor al nivel de significancia ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1,0,0) son independientes, es decir, se comportan como ruido blanco.

**Tabla 329:** Test de Ljung\_Box para los residuos del modelo ARIMA (1,0,0).

---

**Test Ljung-Box**

---

Datos: Residuos del modelo ARIMA (1, 0, 0)

$Q^* = 6.4173$ ,      Grados de libertad = 10,      p\_valor = 0.7791

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

*Prueba de estacionariedad de los residuos*

Para comprobar la estacionariedad de los residuos se aplicó la prueba de Dickey-Fuller.

Las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo ARIMA (1,0,0) son estacionarios.

$H_1$ : los residuos del modelo ARIMA (1,0,0) no son estacionarios.

Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 40 se presentan los resultados de la prueba, observándose que el p valor es mayor o igual al nivel de significancia ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1, 0, 0) son estacionarios.

**Tabla 4033:** Test de Dickey-Fuller para los residuos del modelo ARIMA (1,0,0).

---

**Test de Dickey- Fuller aumentada**

---

Datos: Modelo residuals

Dickey-Fuller = - 3.4691      Orden de retraso = 3      p\_valor = 0.05

Hipótesis alternativa: Estacionaria

---

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.

*Prueba de normalidad*

Para verificar la normalidad de los residuos se aplicó el test de Kolmogórov-Smirnov debido a que el número de registros es mayor a 50. En este caso, las hipótesis contrastadas fueron:

$H_0$ : los residuos del modelo ARIMA (1,0,0) siguen una distribución normal.

$H_1$ : los residuos del modelo ARIMA (1,0,0) no siguen una distribución normal.

#### Criterio de decisión

Si el p valor  $< \alpha$  se rechaza la hipótesis nula.

Si el p valor  $\geq \alpha$  no se rechaza la hipótesis nula.

En la tabla 41 se presentan los resultados de la prueba. Se observa que el p valor es 0.7778 siendo mayor al nivel de significancia ( $\alpha=0.05$ ); por tanto, no se rechaza la hipótesis nula y se concluye que los residuos del modelo ARIMA (1, 0, 0) siguen una distribución normal.

**Tabla 41:** Prueba de normalidad para los residuos del modelo ARIMA (1,0,0).

---

#### Test de Kolmogorov-Smirnov

---

Datos: Residuos del modelo ARIMA (1, 0, 0)

$D = 0.084583$ ,       $p\_valor = 0.7778$

Hipótesis alternativa: dos colas (bilateral)

---

Elaborado por: Gavilanes, 2022.

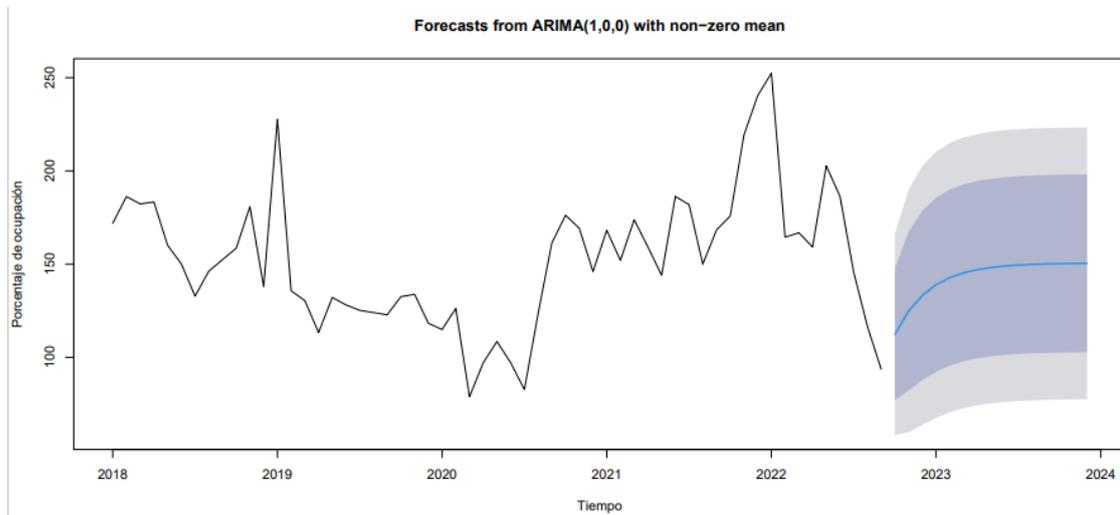
Fuente: Datos del área de emergencia del Hospital Básico Puyo.

La evaluación realizada a los residuos del modelo ARIMA (1, 0, 0) arrojó que estos cumplen con todos los supuestos mencionados previamente, por tanto, se pasa a la etapa de predicción (pronóstico).

#### Predicción en base al modelo

En esta etapa se procedió a realizar el pronóstico para el período enero 2023 – diciembre 2023, observándose que el modelo ARIMA (1,0,0) no pronostica bien, no sigue el comportamiento adecuado, en comparación con la serie original, solo puede apreciarse que el porcentaje de ocupación va aumentando para ese año (figura 28). Por tanto, para obtener un mejor pronóstico se probaron todos los modelos propuestos en la metodología

en el apartado correspondiente al área de emergencia; con el fin de encontrar un modelo que se ajuste a los datos de la serie original.



**Figura 28:** Pronóstico del modelo ARIMA (1,0,0).

Elaborado por: Gavilanes, 2022.

Fuente: Datos del área de emergencia del Hospital Básico Puyo.