

UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA



**MODELAMIENTO UNIVARIADO DEL NÚMERO DE DEFUNCIONES
INFANTILES PRODUCIDAS POR INFECCIONES RESPIRATORIAS
AGUDAS, A TRAVÉS DE LA METODOLOGÍA BOX-JENKINS,
PUNO 2008-2016**

TESIS

PRESENTADA POR:

Bach. SILVIA LUZ BEDOYA LUZA

Para optar el Título Profesional de:

INGENIERO ESTADÍSTICO E INFORMÁTICO

PUNO – PERÚ

2018


UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

MODELAMIENTO UNIVARIADO DEL NÚMERO DE DEFUNCIONES
INFANTILES PRODUCIDAS POR INFECCIONES RESPIRATORIAS AGUDAS,
A TRAVÉS DE LA METODOLOGÍA BOX-JENKINS, PUNO 2008-2016

TESIS PRESENTADA POR:


Bach. SILVIA LUZ BEDOYA LUZA

PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO ESTADÍSTICO E INFORMÁTICO



APROBADA POR:

PRESIDENTE

: 

Mg. EMMA ORFELINDA, AZAÑERO DE AGUIRRE

PRIMER MIEMBRO

: 

M.C. CONFESOR MILÁN, VARGAS VALVERDE

SEGUNDO MIEMBRO

: 

M.Sc. LUIS HUBER, VENTURO ORBEGOSO

DIRECTOR / ASESOR

: 

Dr. LEONEL, COYLA IDME

Área : Estadística
Tema : Series de Tiempo
Fecha de sustentación : 02/07/2018

DEDICATORIA

Al altísimo Divino creador por darme la vida, junto a mis queridos padres y guiarme día a día, que hace más liviano mi camino.

A Don Augusto y Doña Felicitas mis padres; por su amor, comprensión, apoyo moral y constante en mi formación profesional.

A mis hermanas por estar a mi lado, brindándome su apoyo emocional y en mi formación profesional.

A Carlos, Sharom y Fredy en especial por su amistad, apoyo moral, su motivación incondicional y los gratos recuerdos que siempre estarán grabados en mi mente.

AGRADECIMIENTO

A Dios, guía y compañero incondicional hasta en los momentos sesgados de mi vida.

A mis padres y familia en general, por brindarme su apoyo y motivación durante mi permanencia en la universidad.

A la Universidad Nacional del Altiplano y a la Facultad de Ingeniería Estadística e Informática, Escuela Profesional Estadística e Informática, por acogerme en sus aulas.

A los docentes, que me brindaron sus conocimientos, me guiaron y apoyaron en la realización de la presente investigación.

A todas las personas que de alguna u otra forma han colaborado con sus ideas, comentarios y consejos en el desarrollo del presente trabajos de investigación.

INDICE GENERAL

RESUMEN.....	9
ABSTRACT	10
CAPÍTULO I - INTRODUCCIÓN.....	11
1.1. DESCRIPCIÓN DEL PROBLEMA	12
1.2. FORMULACIÓN DEL PROBLEMA.....	13
1.3. OBJETIVO GENERAL Y ESPECÍFICOS	13
1.3.1 Objetivo general.....	13
1.3.2 Objetivos Específicos	13
1.4. HIPÓTESIS DE LA INVESTIGACIÓN	14
1.5. JUSTIFICACIÓN DE LA INVESTIGACIÓN	14
1.6. LIMITACIONES DE LA INVESTIGACIÓN	15
CAPÍTULO II - REVISION DE LITERATURA	16
2.1 ANTECEDENTES DE LA INVESTIGACIÓN	16
2.2 BASE TEÓRICA.....	20
2.2.1 Modelo BOX-JENKINS	25
2.3 DEFINICIÓN DE TÉRMINOS BÁSICOS	35
2.3.1 Enfermedades respiratorias	35
2.3.2 Defunción	36
2.3.3 Demografía.....	36
2.3.4 Determinar.....	36
2.3.5 Distrito	36

2.3.6	Modelo.....	36
2.3.7	Modelo matemático	37
2.3.8	Predicción.....	37
2.3.9	Pronóstico.....	37
2.3.10	Población.....	37
2.3.11	Tasa de mortalidad.....	37
2.4	OPERACIONALIZACIÓN DE VARIABLES	38
	CAPÍTULO III - MATERIALES Y MÉTODOS	39
3.1	POBLACIÓN, MUESTRA Y UNIDAD MUESTRAL	39
3.1.1	Población	39
3.1.2	Muestra:.....	39
3.1.3	Unidad Muestral.....	39
3.2	Diseño de la muestra	39
3.3	Método de recolección de datos	40
3.4	Método de análisis de datos	40
	CAPÍTULO IV - RESULTADOS Y DISCUSIÓN.....	44
4.1	APLICACIÓN DE LA METODOLOGÍA BOX JENKINS.....	44
4.1.1	IDENTIFICACIÓN DEL MODELO	45
	CAPÍTULO V - CONCLUSIONES	57
	CAPÍTULO VI - RECOMENDACIONES.....	58
	CAPÍTULO VII - REFERENCIAS	59
	ANEXO 1.....	62

TABLA DE FIGURAS

Figura 1: Metodología Box Jenkins.....	43
Figura 2: Serie original del número de defunciones mensuales de los años 2008-2016.....	45
Figura 3: Función de Autocorrelación estimada de la serie de defunciones causadas por las I.R.As.....	46
Figura 4: Función de Autocorrelación estimada de la serie de defunciones causadas por las I.R.As.....	47
Figura 5: Primera diferencia no estacional aplicada a la serie	48
Figura 6: Primera diferencia estacional aplicada a la serie	48
Figura 7: Primera diferencia estacional y no estacional de la serie transformada	49
Figura 8: Función de Autocorrelación de la primera diferencia estacional y no estacional de la serie transformada	50
Figura 9: Función de Autocorrelación parcial de la primera diferencia estacional y no estacional de la serie transformada	50
Figura 10: Normalidad de los residuos	52
Figura 11: Función de autocorrelación de residuales estimada de la serie de defunciones causadas por IRAs	53
Figura 12: Función de autocorrelación parcial de residuales estimada de la serie de defunciones causadas por IRAs	54
Figura 13: Secuencia estimada de la serie del número de defunciones infantiles	55

INDICE DE TABLAS

Tabla 1: Modelos estacionales multiplicativos	30
Tabla 2: Operacionalización de variables	38
Tabla 3: Serie histórica mensual del número de defunciones infantiles Puno, periodo 2008-2016	44
Tabla 4: Datos de las predicciones estimadas del modelo ARIMA (0,1,1)(0,1,1) .	55

RESUMEN

El presente trabajo de investigación enfoca su estudio en la provincia de Puno, debido a sus bajas temperaturas que ocasionan enfermedades y en algunos casos hasta la muerte; por lo cual una de las prioridades de estudio es saber las futuras proyecciones del número de defunciones infantiles causadas por las infecciones respiratorias agudas (I.R.AS), en niños menores de 05 años, para prever y así reducir el incremento de muertes, motivo por el cual se tiene como objetivo determinar un modelo univariado que mejor se ajuste a nuestra serie, para poder realizar predicciones a corto plazo.

Los datos fueron recopilados de los registros existentes del número de defunciones infantiles causadas por las infecciones respiratorias agudas (I.R.AS), en niños menores de 05 años de la Dirección Regional de Salud de Puno periodo 2008-2016; estos datos son de suma importancia para programar un determinado presupuesto para el siguiente año.

El resultado obtenido de esta investigación, el mejor modelo univariante para pronosticar la serie del número de defunciones infantiles causadas por las infecciones respiratorias agudas (I.R.AS), en niños menores de 05 años de la Dirección Regional de Salud de Puno es el modelo ARIMA (0, 1,1,)x(1, 1,0), cuya ecuación de pronóstico estimada es:

$$\hat{Y}_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - 0.96796 e_{t-1} - 0.60690 e_{t-12} + 0.58745 e_{t-13}$$

PALABRAS CLAVES: Predicción, I.R.AS, Box-Jenkins, Mortalidad, Univariante.

ABSTRACT

The present work of investigation focuses its study in the province of Puno, due to its low temperatures that cause diseases and in some cases until the death; therefore one of the priorities of study is to know the future projections of the number of infant deaths caused by acute respiratory infections (ARI), in children under 05 years, to foresee and thus reduce the increase in deaths, due to the which aims to determine a univariate model that best fits our series, to make short-term predictions.

The data were compiled from the existing registries of the number of infant deaths caused by acute respiratory infections (I.R.AS), in children under 05 years of the Regional Health Directorate of Puno period 2008-2016; These data are of the utmost importance to schedule a certain budget for the following year.

We analyzed the results obtained by comparing them with the real data to determine the prediction accuracy of the chosen model, confirming that the chosen model is considered adequate for the forecast. The result obtained from this research, the best univariate model to predict the series of the number of infant deaths caused by acute respiratory infections (ARI), in children under 05 years of the Regional Health Directorate of Puno is the ARIMA model (0, 1,1,) x (1, 1,0), whose estimated forecast equation is:

$$\hat{Y}_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - 0.96796 e_{t-1} - 0.60690 e_{t-12} + 0.58745 e_{t-13}$$

KEYWORDS: Prediction, I.R.AS, Box-Jenkins, Mortality, Univariate.

CAPÍTULO I

INTRODUCCIÓN

Es muy importante los modelos de predicción para la prevención y planificación ante ciertos incidentes, hoy en día la mortalidad infantil aumentan en el costo de la atención médica y escasez relativa de los médicos especialistas. Utilizando modelos Box-Jenkins y Redes Neuronales se obtuvieron modelos de predicción ya que en la actualidad son muchos los campos en los que se pueden aplicar estos conocimientos, de manera que permite tomar acertadas decisiones, puesto que se apoyan en técnicas para la aceptación o rechazo de hipótesis y poder actuar a partir de las series observadas, de esta manera predecir el comportamiento de la variable en estudio.

En el capítulo I, se explica los fundamentos para la realización de la tesis, así como planteamiento del problema, justificación objetivos e hipótesis.

En el capítulo II, se describe el marco teórico y presenta los diversos conceptos necesarios para el correcto entendimiento de la tesis, que consiste en: antecedentes de la investigación, base teórica, definición de términos básicos, operacionalización de variables.

En el capítulo III, se describe los materiales y métodos para el modelo de predicción, para el número de defunciones infantiles causadas por las enfermedades respiratorias.

En el capítulo IV, se muestra los resultados del mejor modelo de ajuste para el número de defunciones infantiles causadas por las enfermedades respiratorias.

Por último se muestra, las conclusiones y recomendaciones sobre el modelo univariante integrado de Box-Jenkins

1.1. DESCRIPCIÓN DEL PROBLEMA:

El distrito de Puno, se encuentra en una de las zonas altiplánicas donde las temperaturas son menores y tienden a bajar, siendo este un causante de enfermedades respiratorias en niños y adultos pero siendo más propensa y mortal en niños menores de 05 años; en la mayoría de los países en desarrollo, cerca del 50% de todas las muertes pueden ocurrir después del primer año de vida y antes de los cinco¹. Con todo esto encontramos que uno de los principales problemas de carácter social es la alta incidencia de mortalidad en infantes menores de cinco años, debido a esto surge el interés por ver el comportamiento de dicha variable. La predicción es uno de los instrumentos que permite obtener valores futuros que ha de ocurrir, en función al pasado de las variables cuyo comportamiento interesa describir a través del tiempo, para tomar precauciones sobre sucesos en el futuro, en la población del distrito de Puno.

La estadística clásica para poder predecir utiliza la metodología de Box – Jenkins; en esta metodología los pasos a realizar dependen del tipo de

¹[Http://en.wikipedia.org/wiki/Anita_Hill](http://en.wikipedia.org/wiki/Anita_Hill)

datos, son fáciles de desarrollar e implantar y relativamente fácil de comprender e interpretar.² Aunque al utilizarlos, en series no lineales, presentan limitaciones.

La razón del trabajo, fue realizar un estudio de la serie de tiempo, del número de defunciones infantiles causadas por las infecciones respiratorias agudas (I.R.AS), en niños menores de 05 años del distrito de Puno (periodo 2008 -2016), utilizando la metodología Box – Jenkins para luego comparar los resultados con los datos reales y elegir el mejor modelo, ante todo esto se planteó la siguiente interrogante:

1.2. FORMULACIÓN DEL PROBLEMA:

¿Cuál es el modelo univariante que mejor se ajusta para el pronóstico de la tasa de mortalidad en niños menores de 05 años causados por las I.R.AS?

1.3. OBJETIVO GENERAL Y ESPECÍFICOS:

1.3.1 Objetivo general:

Determinar un modelo univariado del número de defunciones infantiles producidas por infecciones respiratorias agudas, a través de la metodología Box-Jenkins.

1.3.2 Objetivos Específicos:

- Estimar y validar el mejor modelo de predicción para el número de defunciones infantiles producidas por infecciones respiratorias agudas.

² Collantes, Joanna: “Predicción con Redes Neuronales: Comparación con las Metodologías de Box y Jenkins”, Universidad de los Andes, Venezuela 2001

- Realizar una buena predicción para el siguiente año.

1.4. HIPÓTESIS DE LA INVESTIGACIÓN:

El modelo univariado proporciona un mejor ajuste para el pronóstico del número de defunciones infantiles producidas por infecciones respiratorias agudas.

1.5. JUSTIFICACIÓN DE LA INVESTIGACIÓN:

Según el Ministerio de salud (Minsa), en el Perú se estima que tres de cada cuatro consultas que se otorgan en los servicios de los establecimientos de salud para atender enfermedades infecciosas, corresponden a problemas respiratorios agudos, por cuanto constituyen la primera causa de muerte especialmente en los infantes; debido a esto el estudio planteado ayudara a realizar un pronóstico sobre el número de defunciones infantiles causadas por las I.R.As, que será útil para tomar medidas correctivas y solucionar esta situación. Así el Estado y el sector Salud se verán beneficiados, con las predicciones que se realizaran y estarán más preparados para hacer frente a este problema; por otra parte, la investigación contribuirá a realizar más proyectos para más zonas con el mismo problema.

Con esta investigación también se pretende aplicar los conocimientos brindados por la facultad de Ingeniería Estadística e Informática y así mismo aportar nuevos conocimientos referido a la variable de estudio para las futuras investigaciones y que servirá como un antecedente de investigación.

1.6. LIMITACIONES DE LA INVESTIGACIÓN:

La limitación en el presente trabajo de investigación fue la dificultad en la recopilación de información histórica por meses, ya que no se cuenta con la información completa, por lo cual solo se obtuvo la disponible para elaboración de la investigación.

CAPÍTULO II

REVISION DE LITERATURA

2.1 ANTECEDENTES DE LA INVESTIGACIÓN:

- **Quispe (2012)** “Modelo de predicción de los nacimientos y defunciones del distrito de Juliaca-2012” Tesis de pregrado de la Escuela profesional de ingeniería estadística e informática de la Universidad Nacional del Altiplano, Perú. Cuyo objetivo general es: determinar modelos univariantes para la predicción del número de nacimientos y del número de defunciones en la población del Distrito de Juliaca, para el año 2012. Llegando a la siguiente conclusión: Primera.- el modelo de pronóstico univariante integrado ARIMA(2,1,0)x(2,1,3)₁₂ que mejor se ajusta para predecir el número de nacimientos para el año 2012 en el distrito de Juliaca e

$$\begin{aligned} \hat{Y}_t = & Y_{t-1} + Y_{t-12} - Y_{t-13} - 0.80Y_{t-1} + 0.380Y_{t-2} + 0.80Y_{t-13} - \\ & 0.80Y_{t-14} - 0.30Y_{t-2} + 0.30Y_{t-13} + 0.30Y_{t-14} - 0.30Y_{t-15} + 0.80Y_{t-12} - \\ & 0.80Y_{t-13} - 0.80Y_{t-24} + 0.80Y_{t-25} - 0.76Y_{t-24} + 0.76Y_{t-25} + 0.76Y_{t-36} - \\ & 0.76Y_{t-37} + 0.64Y_{t-13} - 0.64Y_{t-14} - 0.64Y_{t-25} + 0.64Y_{t-26} - 0.61Y_{t-25} + \\ & 0.61Y_{t-26} + 0.61Y_{t-37} - 0.61Y_{t-38} + 0.24Y_{t-14} - 0.24Y_{t-25} - 0.24Y_{t-26} + \end{aligned}$$

$$0.24Y_{t-27} - 0.23Y_{t-26} + 0.23Y_{t-37} + 0.23Y_{t-38} - 0.23Y_{t-39} - 2.11\varepsilon_{t-13} + \\ 1.69\varepsilon_{t-24} - 0.51\varepsilon_{t-36}$$

Y el modelo de pronóstico univariante integrado ARIMA (0,1,1)x(2,0,1)₁₂ que mejor se ajusta para predecir el número de defunciones para el año 2012 en el distrito de Juliaca es:

$$\hat{Y}_t = Y_{t-1} + 0.74Y_{t-12} + 0.74Y_{t-13} + \\ 0.53Y_{t-24} - 0.53Y_{t-25} - 0.74\varepsilon_{t-1} + 1.15\varepsilon_{t-12} - 0.85\varepsilon_{t-13}$$

Segunda.- se obtuvieron las predicciones mensuales para el año 2012 para las series de los nacimientos y las defunciones de la población de la provincia de Juliaca con los modelos estimados.

- **Mollinedo (2010)** “Modelos de series de tiempo para el pronóstico de temperaturas ambientales mínimas en el distrito de puno periodo 2000 – 2009, Puno”, Tesis de Pregrado de la Escuela profesional de ingeniería estadística e informática de la Universidad Nacional del Altiplano, Perú. Cuyo objetivo general es: determinar un modelo de series de tiempo eficiente para el pronóstico de las temperaturas mínimas ambientales del distrito de puno, periodo 2000 – 2009. Llegando a la siguiente conclusión: primera: para la identificación del modelo se realizaron algunas transformaciones de BOX COX aplicando para ello $\ln(Y_t + m)$, siendo Y_t la serie original y m la cantidad (9) que se sumó a la serie original para convertirla en positiva. Transformación que posteriormente se quitó para la predicción de los datos originales. Segundo: los modelos de series de tiempo de Box Jenkins proporcionan un mejor ajuste para predecir el comportamiento de las temperaturas ambientales mínimas – distrito de Puno, serie histórica 2000 – 2009. El modelo univariante integrado que

mejor se ajusta según la face de validación y verificación es el modelo SARIMA (1,0,1)(1,1,0) cuya ecuación de pronóstico es:

$$\begin{aligned}\hat{Y}_t = & Y_{t-12} + (-0.4636)Y_{t-12} + (0.3438)Y_{t-1} \\ & - (0.3438)(-0.4636)Y_{t-13} - (-0.4636)Y_{t-24} \\ & - (0.3438)Y_{t-13} + (0.3438)(-0.4636)Y_{t-25} \\ & - (-0.4096)\varepsilon_{t-1}\end{aligned}$$

- **Edwin (2016)** “Modelo de predicción mensual de mortalidad general intrahospitalaria en el Hospital Regional Manuel Núñez Butrón, Puno 2008-2016 I” Tesis de Grado de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano, Perú. Cuyo objetivo general es: Determinar el mejor modelo univariante de predicción mensual del número de mortalidad general intrahospitalaria en el Hospital Regional Manuel Núñez Butrón, Puno 2008-2016 I. Llegando a la siguiente conclusión: Primero, el modelo de predicción mensual que mejor se ajusta para decidir y predecir el comportamiento de la serie de tiempo del número de mortalidad intrahospitalaria es SARIMA (2,1,0)(0,1,1)₁₂. Segundo, al determinar la predicción en los modelos alcanzados para la serie de número de mortalidad intrahospitalaria del Hospital Regional Manuel Nuñez Butrón – Puno, revelan una réplica bastante buena y proporcionan una alternativa eficaz para describir y predecir el comportamiento futuro del número de mortalidad intrahospitalaria, el mejor modelo útil para la predicción es

$$\hat{Y}_t = Y_{t-1} * Y_{t-2} + Y_{t-2} - (0.58)Y_{t-12} - (0.29)Y_{t-13} + \varepsilon_t + 0.999 - \varepsilon_{t-12} +$$

ε_{t-13} , este modelo fue elegido por los criterios de Akaike y Schwarz, y por comparación de datos y ajuste con la serie original.

- **Merlin (2015)** “Modelo univariante de pronóstico del número de unidades de transfusión de sangre en el hospital regional Manuel Núñez Butrón, Puno periodo 2006-2015 I” Tesis de Grado de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano, Perú. Cuyo objetivo general es: Determinar el modelo de predicción mensual que mejor se ajusta para realizar el pronóstico del número de unidades de transfusión de sangre en el hospital regional Manuel Núñez Butrón, Puno. Llegando a la siguiente conclusión: Los modelos de predicción mensual que mejor se ajusta para decidir y predecir el comportamiento de la serie de tiempo del número de unidades de transfusión de sangre es: SARIMA(0,1,1)(1,1,0)12, cuya ecuación de pronóstico es
$$\hat{Y}_t = Y_{t-1} + Y_{t-2} - (0.36)Y_{t-12} - (0.36)Y_{t-13} + \varepsilon_t + (0.89)\varepsilon_{t-1} - \varepsilon_{t-12} + \varepsilon_{t-13} .$$
- **Quispe (2015)** “Modelo univariante para el consumo de energía eléctrica doméstica en el Distrito de Ayaviri – Electro Puno, periodo 2004-2013” Tesis de Grado de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano, Perú. Cuyo objetivo general es: Determinar el modelo univariante de ajuste que nos permita describir y predecir el Consumo de Energía Eléctrica en el distrito Ayaviri – Electro Puno, periodo 2004-2013. Llegando a la siguiente conclusión: El mejor modelo univariante que nos permite describir y predecir el comportamiento del consumo de Energía Eléctrica domestica para el servicio eléctrico de Ayaviri-Electro Puno, es el modelo siguiente:

$$\begin{aligned} \text{ARIMA}(3,1,1)(1,0,1) \quad \hat{Y}_t = & Y_{t-1} - 1.0247 Y_{t-1} - Y_{t-2} + 0.3257 Y_{t-2} - Y_{t-3} - \\ & 0.1801 Y_{t-3} - Y_{t-4} + 0.7447 Y_{t-12} - Y_{t-13} + 0.7630 Y_{t-13} - Y_{t-14} + \\ & 0.2425 Y_{t-14} - Y_{t-15} + 0.1341 Y_{t-15} - Y_{t-16} - 0.6113 \varepsilon_{t-12} - 0.917 \varepsilon_{t-1} - \\ & 0.561 \varepsilon_{t-13} + \varepsilon_t \end{aligned}$$

2.2 BASE TEÓRICA:

a) Técnicas de Predicción

Las predicciones se basan con el uso de los datos anteriores de una variable para predecir su desempeño futuro. A este respecto, los datos anteriores se presentan, generalmente en la forma de series de tiempo. Una hipótesis básica, en la aplicación de las técnicas de predicción, es el desempeño de los datos anteriores que continúan ocurriendo en el futuro inmediato. Evidencias empíricas indican que este supuesto es válido en muchas situaciones reales, sobre todo cuando las series de tiempo se presentan en una larga historia de las variables analizadas.

b) Serie de tiempo

“Es un conjunto de observaciones ordenadas según una característica cuantitativa de un fenómeno individual en diferentes momentos del tiempo, en el cual las observaciones son realizadas.”³

“Una serie de tiempo consta de datos que se reúnen, registran u observan sobre incrementos sucesivos de tiempo. En el análisis de series de tiempo de datos, una tendencia inmediata consiste en intentar explicar y contabilizar el comportamiento de las series. La tendencia de una serie sobre un periodo amplio, el componente cíclico es la fluctuación en forma de onda

³ Anderson, Oliver D.(1985). *Time Serie Analysis and Forecasting*(1ra Edición)

alrededor de la tendencia, el componente estacional es un patrón de cambio que se repite a si mismo año tras año, el componente aleatorio mide la variabilidad de las series de tiempo después de retirar los otros componentes.”⁴

c) Proceso Estocástico

“Un proceso estocástico se define como una familia de variables aleatorias que corresponden a momentos sucesivos del tiempo. Será por $Y(t,u)$, donde t es el tiempo y u es la variable aleatoria. La determinación de las características de un proceso estocástico puede hacerse mediante dos formas alternativas, bien a partir de funciones de distribución conjunta o bien a partir de momentos. En general, para un conjunto finito de valores del tiempo, se obtiene una función de distribución conjunta, así para t_1, t_2, \dots, t_n la función de distribución conjunta sería: $F[Y(t_1), Y(t_2), \dots, Y(t_n)]$. Si se dispone de un conjunto finito de estas variables Y_1, Y_2, \dots, Y_t se dice que esta sucesión de observaciones forma una serie temporal.”⁵

“Se denomina proceso estocástico a la sucesión infinita de variables aleatorias ordenadas.”⁶

d) Ruido Blanco

Un tipo especial de proceso estocástico es el denominado ruido blanco, una variable ε_t se denomina “ruido blanco” si cumple las siguientes condiciones:

- I. $E(\varepsilon_t) = 0 \quad \forall t$
- II. $V(\varepsilon_t) = E(\varepsilon_t^2) = \sigma^2 \quad \forall t$

⁴Hanke, John y Ritsch, Arthur (1996). “*Pronosticos en los negocios*”. (5ta Edición) México, Editorial Prentice Hall Hispanoamérica S.A.

⁵Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

⁶<<http://seh-/e/ha/series.html>>

$$\text{III. } COV(\varepsilon_t) = E(\varepsilon_t, \varepsilon_s) = 0 \quad \forall t \neq s$$

Esto es, la variable Y_t presenta una esperanza constante en el tiempo, e igual a 0; varianza constante e incorrelación temporal (autocorrelación nula). Si se agrega la condición de que la variable X_t se distribuye normal, la condición (III) de incorrelación implica independencia.

Supondremos, salvo que se exprese lo contrario, que la distribución de probabilidad asociada a un ruido blanco es normal, ello significa que las 3 condiciones anteriores pueden sintetizarse en la siguiente expresión:

$$a_t \sim Niid(0, \sigma^2) \quad \forall t$$

Niid: Normales independientes e idénticamente distribuidas.

El término ruido ha sido tomado de la teoría de la comunicación, en esta disciplina, un ruido corresponde a perturbaciones aleatorias que vienen en función de la señal enviada, que es diferente de la señal recibida. Se denomina ruido blanco a una perturbación aleatoria con las características antes planteadas, por analogía con la distribución de energía continua en luz blanca de un cuerpo incandescente⁷.

e) Serie Temporal

“Conjunto de observaciones, una observación por cada una de las variables: Y_1, Y_2, \dots, Y_t . Sinónimo de Cronología.”⁸

“Con los datos procedentes de serie temporal el planteamiento es distinto. Una serie temporal está constituida por unas observaciones. La

⁷ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España

⁸ <<http://seh-/e/ha/series.html>>

información que se maneja en una serie temporal es generalmente de carácter agregado, aunque el grado de agregación dependerá del sistema que se esté tratando. Así, en una empresa se obtiene la serie temporal de ventas mediante agregación de ventas efectuadas a cada uno de los clientes.”⁹

f) Componentes de una Serie temporal:

Una serie de tiempo frecuentemente es examinada con la intención de descubrir patrones históricos que puedan ser útiles en la predicción, para identificar esos patrones es conveniente pensar que una serie de tiempo consiste de varios componentes¹⁰:

- Tendencia: Una serie de tiempo tiene tendencia cuando por largos periodos los valores crecen o decrecen. También puede definirse como cambios en la media.
- Ciclos: Se refiere a movimientos hacia arriba y hacia abajo alrededor del nivel de la tendencia. Estas fluctuaciones, medidas de pico a pico, pueden tener una duración larga.
- Variaciones Estacionales: Son patrones periódicos que ocurren y se repiten cada determinado tiempo, por ejemplo: anualmente. Estas variaciones son usualmente causadas por factores como el clima y las costumbres.
- Fluctuaciones Irregulares: Son movimientos erráticos en una serie de tiempo que no siguen un patrón regular, ni reconocible. Tales movimientos representan “lo que queda” en una serie de tiempo después de que la tendencia, ciclos y variaciones estacionales han sido explicadas.

⁹ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

¹⁰ Bowerman y O’Connell (1993) “Essentials of Business Statistics”

g) Análisis de series de tiempo

“Si el objetivo en un momento determinado del tiempo, un fenómeno económico que muestra dependencia temporal. Para construir el modelo de series de tiempo, lo único que se necesita es la información muestra de la variable a analizar.”¹¹

“Los análisis de regresión y de correlación se refieren a la relación lineal entre dos o más variables. Se emplea el conocimiento de la variable independiente “X” para predecir la variable dependiente “Y”. en el análisis de tiempo la variable independiente es el tiempo. La variable bajo estudio (Y) toma diferentes valores a través del tiempo. De ahí que cualquier variable clasificada en orden cronológico sea una serie histórica. Los periodos pueden ser años, trimestres, mese, semanas y en algunos casos días u horas.”¹²

h) Métodos de Predicción

Pueden obtenerse valores futuros de una serie de tiempo observada mediante una gran variedad de métodos de predicción. Estos métodos pueden clasificarse fundamentalmente en tres tipos:

Subjetivo: Las predicciones se hacen sobre bases subjetivas usando el criterio, la intuición, el conocimiento en el área y otra información relevante¹³. Entre estos métodos están: Ajuste de una curva subjetiva, el método Delphi y comparaciones tecnológicas en tiempo independiente. Ninguno de estos métodos se considerara en este estudio.

¹¹<<http://seh-/e/ha/series.html> >

¹²Hanke, John y Ritsch, Arthur (1996). “*Pronosticos en los negocios*”. (5ta Edición) México, Editorial Prentice Hell Hispanoamérica S.A.

¹³ Charles Chatfield (1978) “Peace & Change- A journal of peace research”

Univariado: Este tipo de método obtiene valores futuros de la serie basándose en el análisis de sus valores pasados, se intenta conseguir un patrón en estos datos, se asume que este patrón continuara en el futuro y se extrapola para conseguir tales predicciones. Son muchos los métodos que encajan en esta categoría, entre estos se encuentran: Extrapolación de curvas de tendencia, suavización exponencial, método de Holt-Winters y método de Box y Jenkins (ARIMA). Este método es un método ampliamente utilizado y es en el que centraremos nuestro interés.

Causal o Multivariado: Involucra la identificación de otras variables que están relacionadas con la variable a predecir. Una vez que esas variables han sido identificadas, se desarrolla un modelo estadístico que describe la relación entre esas variables y la variable a predecir. La relación estadística derivada es entonces usada para predecir la variable de interés¹⁴. Entre estos métodos están: regresión múltiple, modelos econométricos y método de Box y Jenkins (modelo de función de transferencia); este último método es una extensión del modelo ARIMA que consiste en describir la relación entre la variable de entrada y la variable de salida. Aunque el método puede generalizarse para varias variables de entrada, nos concentraremos únicamente en el caso bivariable (una variable de entrada y una de salida).

2.2.1 Modelo BOX-JENKINS

“Es uno de los métodos predictivos y se fundamenta en la estimación eficiente de los parámetros por medio de los procesos iterativos.”¹⁵

¹⁴ Bowerman y O’Connell (1993) “Essentials of Business Statistics”

¹⁵ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

“Modelo Univariante de BOX-JENKINS. Es una serie de tiempo Z_t , basado en la información existente del pasado”¹⁶

Modelo Univariante de BOX-JENKINS NO INTEGRADOS

Son los procesos de Medias Móviles $MA(q)$, Autoregresivos $AR(p)$ y procesos mixtos (p,q) .

a) Modelos Autoregresivos $AR(p)$

$$Y_t = \varphi_1 Y_{t-1} - \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + e_t$$

Donde:

Y_t : Variable respuesta (dependiente) en el tiempo t .

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$: Variable respuesta en los retardos $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ desempeña la función de las variables independientes.

$\varphi_1, \varphi_2, \dots, \varphi_p$: Coeficientes que serán estimados.

p : Retardo máximo (Orden del modelo).

e_t : Terminio de error en el tiempo t que representa los efectos de la variable que no explica el modelo.

Ruido blanco

“Un tipo especial de proceso estocástico es el denominado *ruido blanco*. Una variable a_t se denomina *ruido blanco* si cumple las siguientes condiciones:

$$a) V(\varepsilon_t) = 0 \quad \forall t$$

$$b) V(\varepsilon_t) = E(\varepsilon_t^2) = \sigma^2 \quad \forall t$$

¹⁶ Anderson, Oliver D.(1985). *Time Serie Analysis and Forecasting*(1ra Edición)

$$c) COV(\varepsilon_t, \varepsilon_s) = E(\varepsilon_t, \varepsilon_s) = 0 \quad \forall t$$

Esto es, la variable a_t presenta una esperanza constante en el tiempo, e igual a 0; varianza contante e incorrelación temporal (autocorrelación nula). Si se agrega la condición de que la variable x_t se distribuye normal, la condición (c) de incorrelacin implica independencia, salvo que se exprese lo contrario, que la distribución de probabilidad asociada a un ruido blanco es normal. Ello significa que las 3 condiciones anteriores pueden sintetizar en la siguiente expresión:

$$a_t \sim N_{iid}(0, \sigma^2) \quad \forall t$$

Dónde:

N_{iid} : Normales independientes e idénticamente distribuidas. ¹⁷

b) Media Móvil MA(q)

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Donde:

Y_t : Variable respuesta (dependiente) en el tiempo t.

$a_{t-1}, a_{t-2}, \dots, a_{t-q}$: Errores que siguen el proceso puramente aleatorio desplazados en q periodos a la que se ajusta la serie.

$\theta_{t-1}, \theta_{t-2}, \dots, \theta_{t-q}$: Los parámetros a estimar.

q : Retardo máximo (Orden del modelo).

a_t : Variable llamada ruido blanco.

¹⁷ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

Modelo Univariante de BOX-JENKINS INTEGRADOS

“Son los procesos mixtos integrados ARIMA(p,d,q), proceso estacional mixto integrado ARIMA(p,d,q)x(P,D,Q), procesos de medias móviles exponenciales EWMA, y los procesos de Auto agregación, se considera como los modelos integrados porque interviene la estacionalidad de la serie en estudio ”¹⁸

- Mixtos integrados ARIMA(p,d,q)

$$\varphi(L) = \varphi_p(L)(1 - L)^d(Y_t - \mu) = \theta_q(L)a_1$$

Donde:

$\varphi(L)$: Es el operador autorregresivo generalizado.

$\varphi_p(L)$: Operador autorregresivo estacionario de la serie Y_t .

d : Numero de diferencias necesarias para alcanzar estacionariedad en la serie.

MODELOS ESTACIONALES

“En muchas ocasiones, los datos que se manejan en la elaboración de modelos ARIMA son datos estacionales, es decir, son datos que tienen unas oscilaciones estrictamente periódicas, donde el periodo es igual o inferior al año. En algunas magnitudes, estas oscilaciones obedecen a causas físicas y coinciden con las estaciones del año, como es el caso de la pluviosidad. En otras magnitudes las oscilaciones se deben a causas sociales, económicas,

¹⁸ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

etc. Es decir, a factores humanos que pueden tener a su vez una motivación de orden físico.”

a) Modelos estacionales puros y Estacionarios

Se designara por S al periodo estacional. Así en datos trimestrales $S = 4$, en datos mensuales $S = 12$. Un modelo estacional puro se caracteriza porque solo existe relación entre las observaciones que distan entre si S periodos o múltiplos de S .

✓ Modelo AR(1) Estacional

Un modelo AR(1) estacional, o AR(1) $_s$, viene definido por: $Y_t = \varphi_1 Y_{t-s} + \varepsilon_t$

✓ Otros modelos estacionales puros

Se recoge a continuación los modelos $AR(2)_s$, $MA(2)_s$, y $ARMA(1,1)_s$.

$$\text{Modelo } AR(2)_s : Y_t = \varphi_1 Y_{t-s} + \varphi_2 Y_{t-2s} + \varepsilon_t$$

$$\text{Modelo } MA(2)_s : Y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-s}$$

$$\text{Modelo } ARMA(1,1)_s : Y_t = \varphi_1 Y_{t-s} + \varepsilon_t - \theta_1 \varepsilon_{t-s}$$

En general un modelo ARMA(P,Q) estacional puro tendrá la siguiente formulación: $Y_t = \varphi_1 Y_{t-s} - \dots - \varphi_p Y_{t-ps} = \varepsilon_t - \theta_1 \varepsilon_{t-s} - \dots - \theta_q \varepsilon_{t-qs}$

b) Modelos estacionales multiplicativos estacionarios

“Modelo general mixto, o multiplicativo, ARMA(p,q)xARMA(P,Q) $_s$.

$$\varphi_s(L)Y_t = \theta_s(L)\varepsilon_t$$

Considerando MA(1)xMA(1) $_s$, cuya expresión será la siguiente tomando $S=12$: $Y_t = (1 - \theta_1 L)(1 - \theta_1 L^{12})\varepsilon_t$

Utilizando solo parámetros ordinarios: $Y_t = \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_{12}\varepsilon_{t-12} - \theta_{13}\varepsilon_{t-13}$ ¹⁹

✓ **Modelo ARMA(0,1)xARMA(0,1)s**

La expresión analítica de este modelo es la siguiente:

$$Y_t = (1 - \theta_1 L)(1 - \theta_1 L^{12})\varepsilon_t$$

✓ **Modelo ARMA(0,2)xARMA(0,1)s**

La expresión analítica de este modelo es la siguiente:

$$Y_t = (1 - \theta_1 L - \theta_2 L^2)(1 - \theta_1 L^{12})\varepsilon_t$$

✓ **Modelo ARMA(0,1)xARMA(1,0)s**

Analíticamente el modelo viene dado por la siguiente expresión:

$$(1 - \varphi_1 L^s Y_t) = (1 - \theta_1 L)\varepsilon_t$$

✓ **Modelo ARMA(1,0)xARMA(1,0)**

Un modelo de este tipo viene dado por la siguiente expresión:

$$(1 - \theta_1 L)(1 - \varphi L^s)Y_t = \varepsilon_t$$

Como resumen de los modelos estacionales puede construirse el siguiente cuadro:

Tabla 1: Modelos estacionales multiplicativos

Modelos	FACT	FACPT
AR(P)xAR(P)s	Decaimiento exponencial y/o oscilaciones sinusoidales atenuadas.	Se anula para $t > p + sP$
MA(q)xMA(Q)s	Se anula para $t > q + sQ$	Decaimiento exponencial y/o oscilaciones sinusoidales atenuadas.

¹⁹ Uriel Jiménez, Ezequiel. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

Función de Autocorrelación Muestral y Función de Autocorrelación Parcial: SAC y SPAC

“Los modelos de pronósticos de Box-Jenkins se identifican en forma tentativa examinando el comportamiento de la función de autocorrelación muestral (SAC) y la función de autocorrelación parcial muestral (SPAC) para los valores de una serie temporal estacionaria Z_b, Z_{b+1}, \dots, Z_n . En este caso Z_b, Z_{b+1}, \dots, Z_n podrían ser los valores originales de la serie temporal o los valores transformados.”²⁰

✓ **Función de Autocorrelación muestral (SAC)**

“Considere la serie de trabajo de valores Z_b, Z_{b+1}, \dots, Z_n . La autocorrelación muestral en el desfase k , denotado por r_k .

La fórmula esta denotada por:
$$r_k = \frac{\sum_{t=b}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=b}^n (Z_t - \bar{Z})^2}$$

Esta cantidad mide la relación lineal entre las observaciones de la serie temporal separadas por un desfase de k unidades de tiempo. Se puede demostrar que r_k siempre estar entre -1 y 1. Un valor de r_k cercano a uno quiere decir, que las observaciones separadas por un desfase de k unidades de tiempo, tienen una fuerte tendencia a moverse juntas en forma lineal con pendiente lineal con pendiente positiva. Por otro lado, un valor de k unidades de tiempo, tienen una fuerte tendencia de desplazarse juntas en forma lineal con pendiente negativa.”²¹

²⁰ Bruce L. Bowerman, Richard T. O’Connell, Anne B. Koehler, “Pronósticos, series de tiempo y regresión”, Cuarta Edición 2007. CeagageLearning

²¹ Bruce L. Bowerman, Richard T. O’Connell, Anne B. Koehler, “Pronósticos, series de tiempo y regresión”, Cuarta Edición 2007. CeagageLearning

✓ **Función de autocorrelación parcial muestral (SPAC)**

“Se presenta las formulas de la función de autocorrelación parcial de la muestra en el desfaseamiento k , r_{kk} , el error estándar de r_{kk} , y la estadística t relacionada, se define la función de autocorrelación parcial de la muestra”²²

La función de autocorrelación parcial de la muestra es el desfaseamiento k es:

$$r_{kk} = \begin{cases} r_1 & \text{si } k=1 \\ \frac{r_{1-\sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j} & \text{si } k = 2,3,\dots \end{cases}$$

Donde: $r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j}$ ($j=0,1,2,\dots,k-1$)

a. El error estándar es r_{kk} es: $S_{r_{kk}} = \frac{1}{(n - b + 1)^{1/2}}$

b. La estadística de $t_{r_{kk}}$ es: $t_{r_{kk}} = \frac{r_{kk}}{S_{r_{kk}}}$

MODELOS ARIMA

“Los modelos ARIMA adquieren su mayor protagonismo en la predicción a corto plazo de series de frecuencia inferior a la anual (trimestral, mensual o incluso diaria). Por ello el tratamiento de la estacionalidad tiene un papel central en la metodología.

En series con estacionalidad no solo hay que modelizar la componente regular(o no estacional) sino también la componente estacional. En esos casos.”

²²Bruce L. Bowerman, Richard T. O’Connell, Anne B. Koehler, “Pronósticos, series de tiempo y regresión”, Cuarta Edición 2007. Ceagage Learning

“Si la serie Y_t tiene una componente con periodo s es posible eliminarla diferenciando con un rezago de orden s , es decir, transformando Y_t a:

$$W_t = (1 - L^s)^D Y_t = \Delta_s^D Y_t, \quad D = 0,1,2 \dots$$

✓ **Modelo Multiplicativo ARIMA**

Sin embargo, si hay estacionalidad, pueden existir estructuras ARIMA intra periodo y entre los s periodos.

Las ARIMA intra se refieren a modelos de la forma:

$$\varphi_p(L)\Delta^d Y_t = \theta_q(L)\varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2)$$

Los ARIMA entre se refieren a modelos ARIMA(P, D, Q)_s de la forma:

$$\varphi_p(L^s)\Delta_s^D Y_t = \theta_q(L^s)\varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2)$$

Y se define el modelo ARIMA(p, q, d)(P, D, Q)_s como:

$$\varphi_p(L)\varphi_P(L^s)\Delta^d \Delta_s^D Y_t = \theta_q(L)\theta_Q(L^s)\varepsilon_t$$

Dónde:

$$X_t = \Delta^d \Delta_s^D Y_t = \theta_q(L)\theta_Q(L^s)\varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma^2)$$

La operación inicial es calcular la serie diferenciada X_t y es similar a eliminar una tendencia, estacionalidad aleatorias y determinísticas para luego ajustar un modelo ARMA a los residuos estructurales.

DESCRIPCIÓN TEÓRICA DE LOS PROCEDIMIENTOS DE DETECCIÓN DE RAICES UNITARIAS

El número de diferencias que habrá que tomar en la serie para convertirla en estacionaria en media, viene dado justamente por el número de

raíces unitarias de la serie original, se determina formalmente mediante los procedimientos de Dickey-Fuller y de Phillips Perron.

El planteamiento más sencillo de Dickey-Fuller es el siguiente: plantean un modelo autoregresivo AR(1) como: $y_t = \mu + \rho y_{t-1} + \varepsilon_t$

Donde μ y ρ son parámetros a estimar y ε_t es un término de error para el que asume que cumple las propiedades de ruido blanco. Dado que ρ es mayor que la unidad, entonces se dice que la serie es explosiva. De esta forma, la hipótesis de estacionariedad de una serie puede ser evaluada analizando si el valor absoluto de ρ es estrictamente menor que 1. Pues bien, el test DF plantea, sencillamente contrastar estadísticamente si $\rho = 1$.

Puesto que en economía las series explosivas no tienen mucho sentido, esta hipótesis nula se analiza frente a la alternativa que establece que:

$$H_1: \rho < 1$$

Se puede demostrar que una expresión equivalente a la anterior, mediante la toma de diferencias, viene dada por:

$$\Delta Y_t = \mu + \gamma Y_{t-1} + \varepsilon_t$$

Donde $\gamma = \rho - 1$ y las hipótesis nula y alternativa son: $H_0: \gamma = 0$

$$H_1: \gamma < 0$$

Aunque el test calcula un estadístico t sobre el valor estimado de γ , bajo la hipótesis nula de existencia de una raíz unitaria, este estadístico no

tiene la distribución convencional de la t-Student. Por ello Dickey y Fuller simularon los valores críticos para una selección de distintos tamaños muestrales, simulación ampliada posteriormente por MacKinnon.

Por lo tanto, aunque el primer paso, para la detección de raíces unitarias debe ser especificar un test DF simple, y después contrastar estadísticamente las características de ruido blanco de los residuos (estadístico Q de Ljung - Box).

El test de Phillips Perron es un método no paramétrico para controlar la correlación de orden elevado en una serie.

2.3 DEFINICIÓN DE TÉRMINOS BÁSICOS

2.3.1 Enfermedades respiratorias:

Las enfermedades respiratorias ocasionaron, en su mayoría, muertes de menores de cinco años y fueron la tercera causa de mortalidad en este grupo, después de las afecciones perinatales y las anomalías congénitas. La mayoría de las muertes por enfermedades respiratorias ocurren antes del año de edad, especialmente entre los dos y tres meses. La neumonía es la principal causa de mortalidad por enfermedades respiratorias en menores de cinco años, seguida por las enfermedades de las vías respiratorias inferiores no especificadas y por las enfermedades del pulmón debidas a agentes externos. La mayoría de las muertes por enfermedad respiratoria se registra entre los meses en los que la temperatura es baja (tiempo de helada).

El riesgo de morir durante la primera infancia debido a una enfermedad respiratoria es de un 15% (aprox.) más alto que el de morir por causas

externas, y un 79% (aprox.) más alto que el de morir por enfermedades infecciosas y parasitarias.²³

2.3.2 Defunción:

Cesación de la vida de un ser perteneciente a la sociedad o la separación de un integrante de la población.

2.3.3 Demografía:

La demografía se ocupa de la descripción estadística de las poblaciones humanas en las que respecta a su estado en una fecha dada; y a los hechos demográficos que se producen en esas poblaciones.

2.3.4 Determinar:

Indicar con precisión o señalar un valor exacto para una solución de una determinada prueba de los datos o cálculo de los datos.

2.3.5 Distrito:

Cada una de las demarcaciones en que se subdivide un territorio o una población con el fin administrativo o jurídico.

2.3.6 Modelo:

Es la presentación matemática de las variables en estudio y los parámetros que son estimados, con fines de predicción del comportamiento futuro de la variable en estudio.

²³Dr. Juan Carlos Bossio, Jefe del Departamento Programas de Salud. Instituto Nacional de Enfermedades Respiratorias "Emilio Coni" 2007.

2.3.7 Modelo matemático:

Es la representación numérica de un problema básico, en el cual el comportamiento del sistema está representado por un conjunto de ecuaciones acompañadas de relaciones lógicas.

2.3.8 Predicción:

Anunciar algo que ha de ocurrir en el futuro en función de hechos pasados de la misma variable analizada, en series de tiempo los datos deben ser tomados en momentos sucesivos de tiempo para su análisis.

2.3.9 Pronóstico:

Conocer con algunos indicios el futuro de lo que puede suceder la variable en estudio en función de los hechos pasados del mismo.

2.3.10 Población:

Es el número de habitantes ubicados geográficamente en una determinada región o demarcados políticamente.

2.3.11 Tasa de mortalidad:

Es la población entre los fallecidos de todas las edades, durante un periodo determinado generalmente un año, la población media de ese periodo.

2.4 OPERACIONALIZACIÓN DE VARIABLES

Por ser una variable directa el cuadro se detalla de la siguiente manera:

Tabla 2: Operacionalización de variables

VARIABLE	INDICADOR	INDICE
Variable Dependiente:		
Número de defunciones en niños menores de 5 años causados por las I.R.AS.	Número de defunciones	Número de defunciones
Variable Independiente:		
Tiempo	Periodo de registro de datos	Meses

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1 POBLACIÓN, MUESTRA Y UNIDAD MUESTRAL

3.1.1 Población: La población en estudio estuvo conformada por el número de defunciones mensuales en niños menores de 5 años causadas por las I.R.AS en la población del distrito de Puno.

3.1.2 Muestra: La muestra estuvo conformada por el número de defunciones mensuales, elegida a criterio por la disponibilidad de los datos, el periodo de tiempo comprendido desde el año 2008 hasta el año 2016, en datos mensuales, siendo $n = 108$.

3.1.3 Unidad Muestral: Nuestra unidad muestral es el niño menor de 5 años que falleció a causa de las I.R.AS en el distrito de Puno.

3.2 Diseño de la muestra

Nuestra muestra está comprendida en el periodo Enero 2008 hasta Diciembre 2016 en datos mensuales, siendo $n = 108$.

3.3 Método de recolección de datos

La información estadística para realizar el presente trabajo de investigación fue extraída del archivo de la Dirección Regional de Salud Puno, en datos mensuales correspondiente entre el periodo 2008 hasta 2016.

3.4 Método de análisis de datos

Metodología de BOX-JENKINS

La metodología de Box-Jenkins es uno de los métodos predictivos que se fundamenta en la estimación de los parámetros por medio de procesos iterativos, consta de cuatro fases, los cuales son:

a) Identificación

Se trata de elegir uno de los modelos como posibles candidatos para explicar el comportamiento de la serie.

El primer paso en la identificación del modelo consiste en determinar si la serie es estacionaria, es decir si el valor de la media varía a través del tiempo.

Si la serie no es estacionaria, en general se puede convertir a serie estacionaria mediante el método de diferenciación. El analista especifica el grado de diferenciación y el algoritmo de Box-Jenkins convierte los datos en serie estacionaria y realiza los cálculos subsecuentes utilizando los datos transformados. En términos generales el analista debe de identificar las autocorrelaciones que hacen exponencialmente a cero. Si las autocorrelaciones descienden exponencialmente de cero, el proceso indicado

es el AR si son las autocorrelaciones parciales las que descienden a cero el proceso indicado es el MA, y sí; tanto los coeficientes de autocorrelación como los coeficientes de autocorrelación parcial descienden a cero el indicado es el proceso mixto ARIMA. El analista puede determinar el orden de los procesos AR y/o MA contando el número de coeficientes de autocorrelación y autocorrelación parcial que son diferentes de cero en forma significativa.

b) Estimación

Se realiza la estimación de los parámetros de los modelos seleccionados. Una vez seleccionado el método tentativo se deben estimar los parámetros para ese modelo. Antes de usar el modelo para pronosticar, el analista debe verificar si es adecuado este paso, se realiza revisando los términos de error para asegurarse que son aleatorios. Esta verificación puede hacerse revisando que las autocorrelaciones de los términos de error, para estar seguros de que no son diferentes de cero de manera significativa, entonces el modelo resulta inadecuado. En este caso es volver de nuevo a la etapa 1, es posible que se puedan juzgar dos o más modelos como aproximadamente iguales, aunque ninguno de ellos ajuste exactamente los datos. En este caso debe prevalecer el principio de parsimonia y elegir el modelo más sencillo.

c) Verificación o Validación

Se comprueba la adecuación del modelo estimado y se verifica que cumpla las propiedades respectivas.

Después de identificar y estimar un modelo, el analista está obligado a diagnosticar el modelo usando pruebas estadísticas bien definidas estas pruebas incluyen:

- ✓ Una prueba estadística de los parámetros del modelo.
- ✓ Un análisis de la gráfica de los resultados para mayor confirmación de la aleatoriedad y lo estacionario en nivel y varianza.

Precisión del pronóstico

Cuando este proceso permite establecer en el futuro, se pueden obtener pronósticos muy precisos.

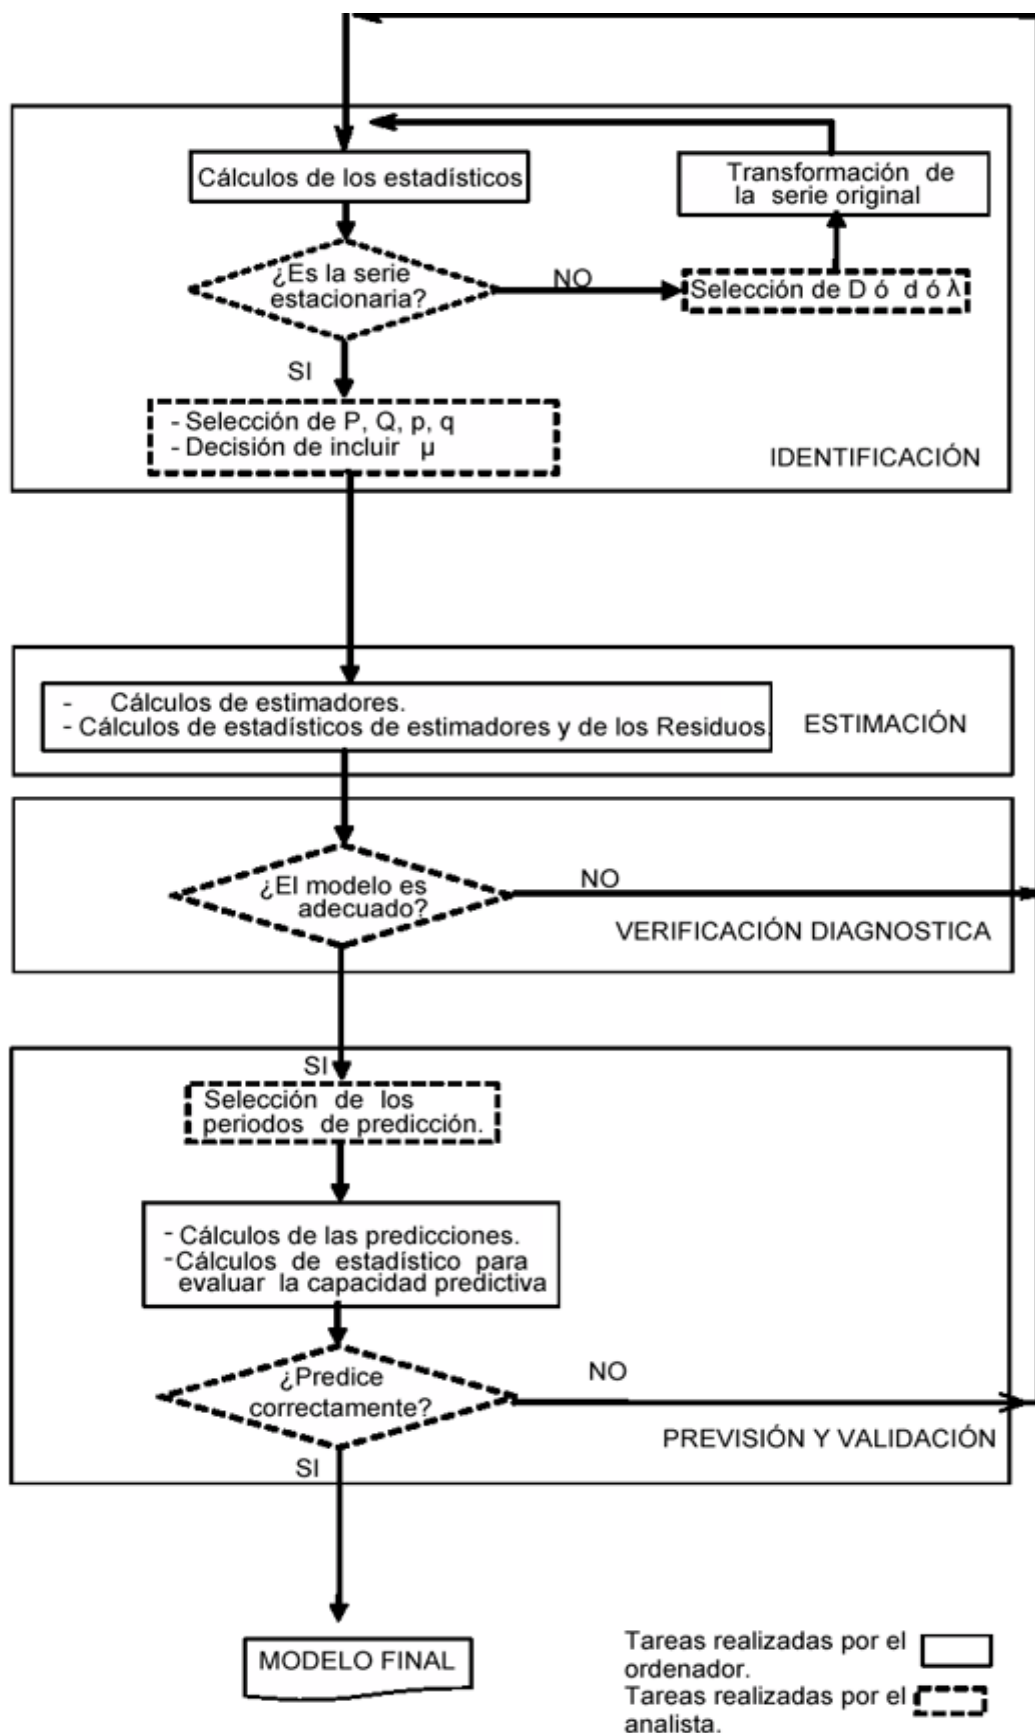
Son valores proyectados a partir de una regresión calculada, aplicado a los coeficientes de regresión sobre las variables independientes.

d) Pronóstico o Predicción

Si el modelo elegido es satisfactorio se realizan las predicciones de la variable.

Una vez que se encontró un modelo adecuado pueden realizar pronósticos para uno o varios periodos. También se pueden formular intervalos de confianza sobre estas estimaciones. En general entre más a futuro se pronostica, mayor será el intervalo e confianza, estos pronósticos e intervalos de confianza se calculan mediante el programa de Box-Jenkins a solicitud del analista. Al haber más datos disponibles, se pueden utilizar el mismo modelo para revisar los pronósticos seleccionando otro periodo de origen. Si la serie parece cambiar a través del tiempo, pudiera ser necesario recalcular los parámetros o incluso desarrollar un modelo nuevo por completo.

Figura 1: Metodología Box Jenkins



CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 APLICACIÓN DE LA METODOLOGÍA BOX JENKINS

A continuación se presentan el consolidado de la serie mensual del número de defunciones infantiles producidas por infecciones respiratorias agudas en niños menores de 05 años del distrito de Puno, correspondientes a los periodos 2008 a 2016, obtenidos de registros realizados en la Dirección Regional de Salud de Puno.

Tabla 3: Serie histórica mensual del número de defunciones infantiles Puno, periodo 2008-2016


	Defunciones causadas por I.R.As en años								
	2008	2009	2010	2011	2012	2013	2014	2015	2016
Enero	4	4	3	6	3	2	3	2	3
Febrero	1	2	2	2	1	3	1	1	1
Marzo	2	1	1	2	2	2	3	1	2
Abril	0	2	1	0	2	1	2	2	0
Mayo	6	5	4	2	3	5	1	2	2
Junio	4	4	2	4	0	4	2	3	1
Julio	6	5	5	5	4	4	4	3	3
Agosto	5	3	4	3	3	7	0	2	2
Setiembre	3	2	3	2	5	2	2	3	2
Octubre	1	1	2	2	2	1	1	1	1
Noviembre	2	1	0	0	2	0	1	2	0
Diciembre	6	5	4	4	0	1	1	0	0

Fuente: Oficina de estadística de la Dirección Regional de Salud de Puno
Elaborado: Por el Investigador

En la tabla N°3 de los datos de defunciones, se puede observar el número mayor de defunciones 7, corresponde al mes de Agosto del año 2013 y teniendo presente que el número menor de defunciones 0 se encuentra presente en los meses Abril, Junio, Agosto, Noviembre y Diciembre en los años 2008, 2010, 2011, 2012, 2014, 2015 y 2016 respectivamente, encontrándose los promedios de cada mes de Enero a Diciembre: 3, 2, 2, 1, 4, 3, 5, 3, 3, 1, 1, 3 promedios anuales del año 2008 a 2016: 4, 3, 3, 3, 2, 3, 2, 2,1.

4.1.1 IDENTIFICACIÓN DEL MODELO:

Figura 2: Serie original del número de defunciones mensuales de los años 2008-2016

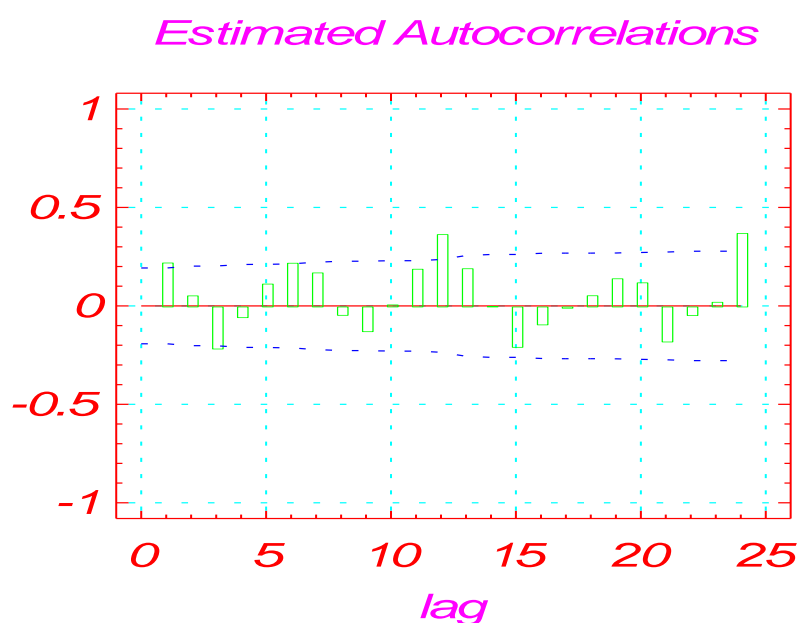


Fuente: Software Statgraphics

En el gráfico se puede visualizar que la serie muestra muchos picos los cuales parecen estar espaciados con una pequeña tendencia decreciente, estos picos indican que nuestra serie tiene mucha variabilidad.

FUNCIÓN DE AUTOCORRELACIÓN

Figura 3: Función de Autocorrelación estimada de la serie de defunciones causadas por las I.R.As




Fuente: Software Statgraphics

En el gráfico el comportamiento de la función de autocorrelación es de forma sinusoidal, observamos además que los retrasos 1,3,6,12 y 24 son significativamente diferentes a cero.

FUNCIÓN DE AUTOCORRELACIÓN PARCIAL

Figura 4: Función de Autocorrelación estimada de la serie de defunciones causadas por las I.R.As



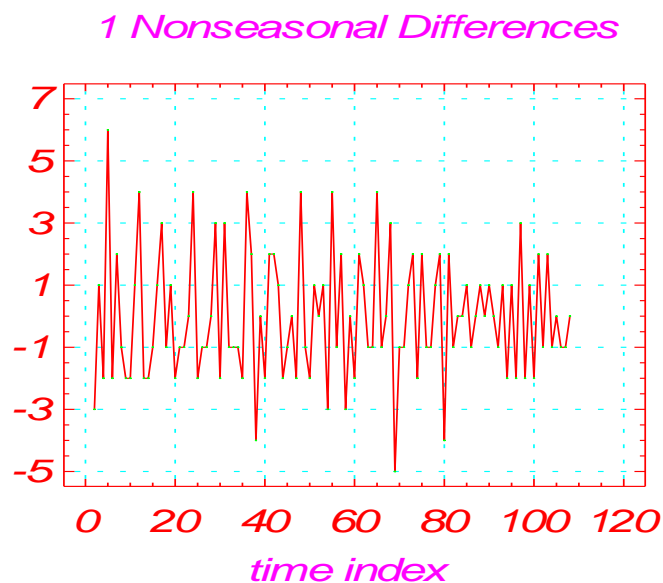
Fuente: Software Statgraphics

En el gráfico de autocorrelación parcial los retardos 1, 3, 12, 21 y 24 son significativamente diferentes a cero, el resto de valores están dentro del intervalo de confianza definido.

PRIMERA DIFERENCIA NO ESTACIONAL

Para que la serie del número de defunciones infantiles producidas por infecciones respiratorias agudas en niños menores de 05 años del distrito de Puno, periodos 2008 – 2016, sea estacionaria en media se debe de transformar con la primera diferencia no estacional

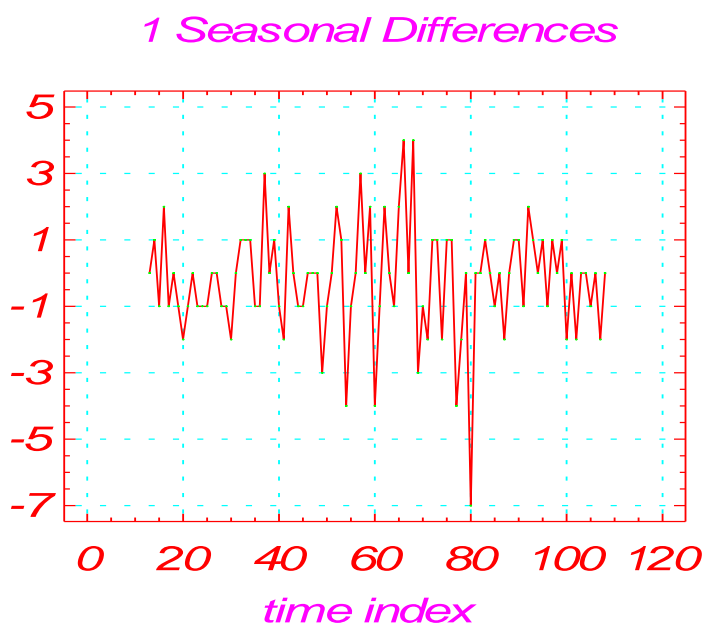
Figura 5: Primera diferencia no estacional aplicada a la serie



Fuente: Software Statgraphics

Al realizar esta primera diferencia no estacional se pierde el primer dato de la serie.


Figura 6: Primera diferencia estacional aplicada a la serie



Fuente: Software Statgraphics

A continuación se realizó la primera diferencia estacional en esta diferencia perderemos 12 datos de nuestra serie.

Figura 7: Primera diferencia estacional y no estacional de la serie transformada

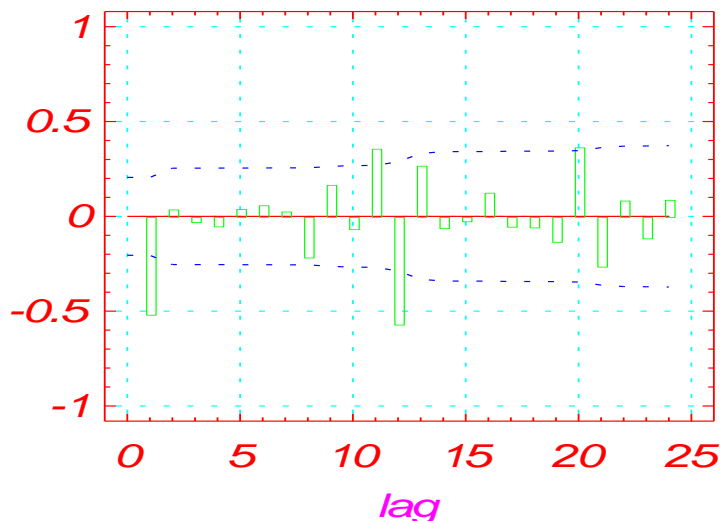


Fuente: Software Statgraphics

Al realizar ambas diferencias estacional y no estacional se pierden 13 datos, a continuación podemos observar la función de autocorrelación y función de autocorrelación parcial de nuestra serie transformada.

Figura 8: Función de Autocorrelación de la primera diferencia estacional y no estacional de la serie transformada


Estimated Autocorrelations for 1 Nonseasonal Differences 1 Seasonal



Fuente: Software Statgraphics

Figura 9: Función de Autocorrelación parcial de la primera diferencia estacional y no estacional de la serie transformada

Estimated Partial Autocorrelations for 1 Nonseasonal Differences 1 Seasonal



Fuente: Software Statgraphics

Observando las Funciones de Autocorrelación y Autocorrelación Parcial podemos ver que tienen una forma sinusoidal esta es una característica del modelo de medias móviles.

MODELO IDENTIFICADO

Modelo ARIMA Multiplicativo (0,1,1)(0,1,1)

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + \varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_{12}\varepsilon_{t-12} + \theta_{13}\varepsilon_{t-13}$$

4.1.2 ESTIMACIÓN DEL MODELO IDENTIFICADO

Summary of Fitted Model for: SILVIA.IRAS

Parameter	Estimate	Std.error	T-value	P-value
MA (1)	.96796	.02356	41.07852	.00000
SMA(12)	.60690	.08760	6.92820	.00000

Model fitted to differences of order 1

Model fitted to seasonal differences of order 1 with seasonal length = 12

Estimated white noise variance = 1.94001 with 93 degrees of freedom.

Estimated white noise standard deviation (std err) = 1.39284

Chi-square test statistic on first 20 residual autocorrelations = 20.4327
with probability of a larger value given white noise = 0.308991

ESTIMACIÓN DE LOS PARÁMETROS PARA EL MODELO DE PRONÓSTICO SELECCIONADO: ARIMA (0,1,1) (0,1,1)

$$\hat{Y}_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - \hat{\theta}_1 e_{t-1} - \hat{\theta}_{12} e_{t-12} + \hat{\theta}_{13} e_{t-13}$$

Si:

$$\hat{\theta}_{13} = \hat{\theta}_1 * \hat{\theta}_{12}$$

Reemplazando: $\widehat{\theta}_{13} = 0.96796 * 0.60690$


$$\widehat{\theta}_{13} = 0.587454924$$

$$\widehat{Y}_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - 0.96796 e_{t-1} - 0.60690 e_{t-12} + 0.58745 e_{t-13}$$

4.1.3 VALIDACIÓN DEL MODELO

Después de seleccionar un modelo ARIMA particular y de estimar sus parámetros, se trata de ver si el modelo seleccionado se ajusta a los datos en forma razonablemente buena, el detalle se encuentra en ver la medida en que los residuos del modelo estimado se aproximan al comportamiento de un ruido blanco.

Figura 10: Normalidad de los residuos

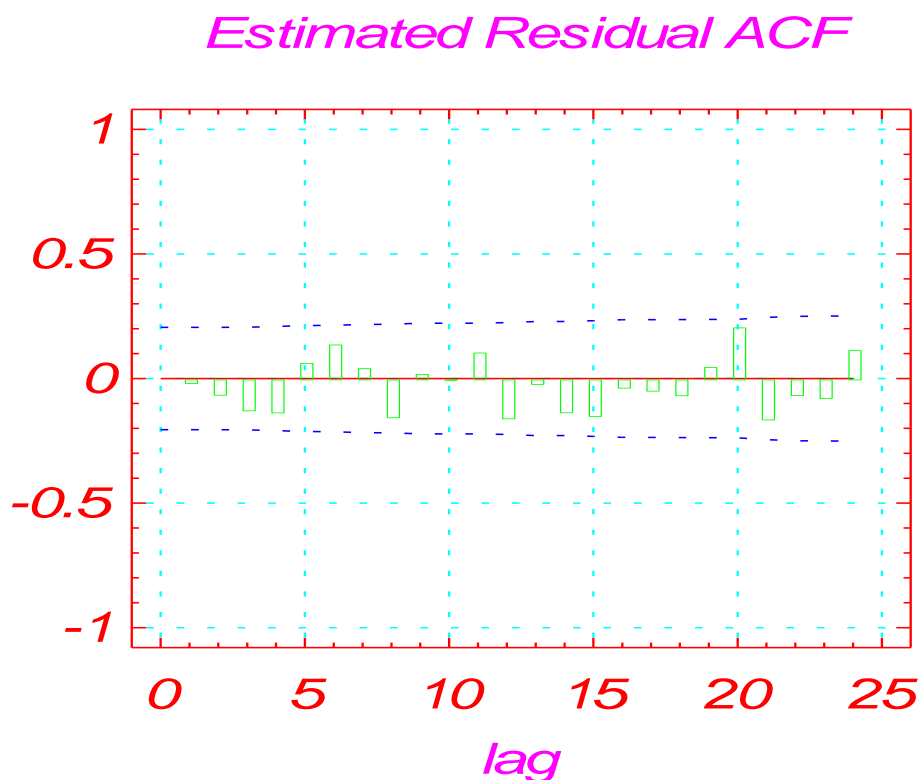


Fuente: Software Statgraphics

FUNCIÓN DE AUTOCORRELACIÓN DE LOS RESIDUALES

(ARIMA (0,1,1) (0,1,1))

Figura 11: Función de autocorrelación de residuales estimada de la serie de defunciones causadas por IRAs



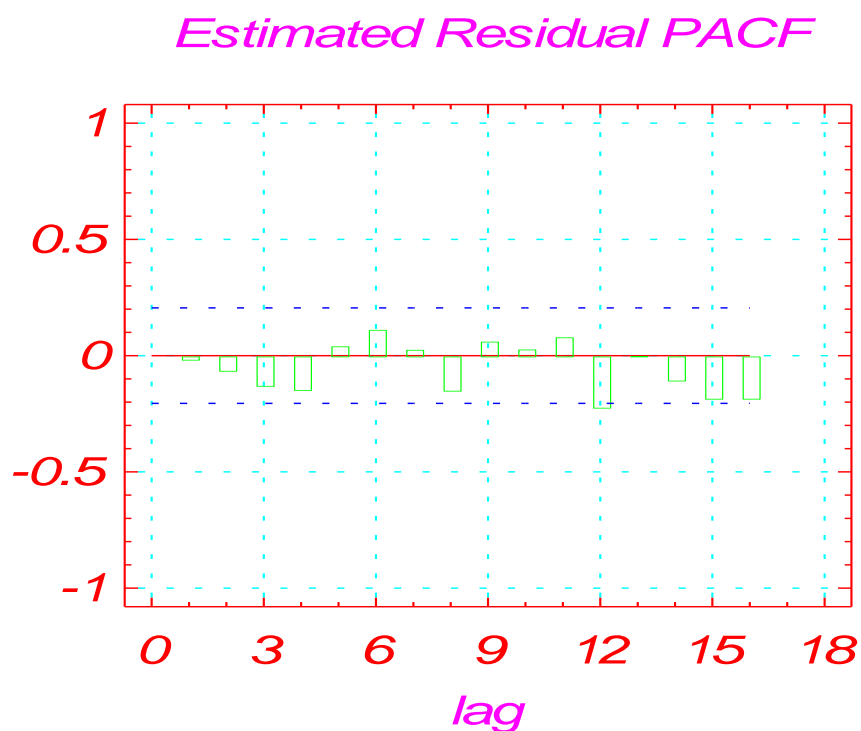
Fuente: Software Statgraphics

En el gráfico los valores de la función de autocorrelación no son significativos en ningún retardo, debido a que todos se encuentran dentro del intervalo de confianza, por lo que se puede afirmar que los datos de la serie del número de defunciones infantiles causadas por las infecciones respiratorias agudas (I.R.As) son aleatorios.

FUNCIÓN DE AUTOCORRELACIÓN PARCIAL DE LOS RESIDUALES

(ARIMA (0,1,1) (0,1,1))

Figura 12: Función de autocorrelación parcial de residuales estimada de la serie de defunciones causadas por IRAs



Fuente: Software Statgraphics

En el gráfico podemos observar la distribución de la función de autocorrelación parcial identificando que el retardo 12 es un poco significativo, pero no es muy relevante ya que es el único, por lo que se concluye que la serie es aleatoria.

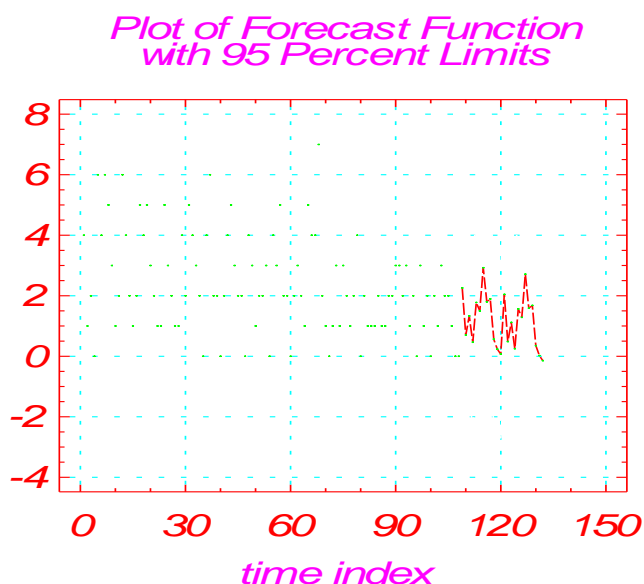
4.1.4 REALIZACIÓN DEL PRONÓSTICO CON EL MODELO

Tabla 4: Datos de las predicciones estimadas del modelo ARIMA (0,1,1)(0,1,1)

AÑO	PRONOSTICO	INTERVALO DE CONF. 95%	
Ene-17	2	0	5
Feb-17	1	0	3
Mar-17	1	0	4
Abr-17	0	0	3
May-17	2	0	4
Jun-17	2	0	4
Jul-17	3	0	6
Ago-17	2	0	4
Set-17	2	0	4
Oct-17	1	0	3
Nov-17	0	0	3
Dic-17	0	0	3

Fuente: Software Statgraphics, tabla diseñada por el investigador

Figura 13: Secuencia estimada de la serie del número de defunciones infantiles



Fuente: Software Statgraphics

En el gráfico se muestran las predicciones con límites del 95%, los límites muestran en donde podría estar el valor verdadero, al tiempo futuro seleccionado, asumiendo que el modelo ajustado es apropiado y corroborando con los datos

originales que caen dentro del intervalo de predicción 95%. La predicción del número de defunciones infantiles causadas por las infecciones respiratorias agudas presenta una tendencia decreciente.

Siempre es bueno contar con un modelo que realice predicciones más precisas, como lo es el modelo propuesto, ya que conocer el comportamiento futuro, o al menos contar con una aproximación más cercana a la real, nos brinda la posibilidad de tomar mejores decisiones en un ambiente incierto.

CAPÍTULO V

CONCLUSIONES

- El modelo de pronóstico univariante integrado seleccionado que mejor se ajusta para predecir el número de defunciones infantiles producidas por infecciones respiratorias agudas, en la población del distrito de Puno es ARIMA (0, 1,1,) (0, 1,1), cuya ecuación de pronóstico estimada es:

$$\hat{Y}_t = Y_{t-1} + Y_{t-12} - Y_{t-13} - 0.96796 e_{t-1} - 0.60690 e_{t-12} + 0.58745 e_{t-13}$$

- Los resultados predictivos evaluados para la serie de número de defunciones infantiles producidas por infecciones respiratorias agudas proporcionan una alternativa eficaz para describir y predecir el comportamiento futuro de nuestra variable.

CAPÍTULO VI

RECOMENDACIONES

A los directivos de la Universidad Nacional del Altiplano, implementar la biblioteca con nuevas bibliografías actualizadas para el fácil acceso a temas novedosos como lo es Redes Neuronales Artificiales.

A futuros investigadores, una mayor experimentación con nuevos casos de estudio podría ser recomendable para corroborar lo expuesto anteriormente, así como el interés en experimentar con nuevas metodologías y/o técnicas en serie de tiempo, tales como Redes Neuronales; esto permitiría establecer comparaciones entre diferentes métodos y probablemente mejorar las predicciones.

Para futuras investigaciones, reforzar la investigación en el tema de Redes Neuronales Artificiales aplicada a la Estadística, se recomienda evaluar series con datos que presentan diferentes patrones en su comportamiento para verificar la influencia de utilizar más datos en el entrenamiento y predicción con redes neuronales.

CAPÍTULO VII

REFERENCIAS

TEXTOS DE CONSULTA

Anderson, O. D.(1985). *Time Serie Analysis and Forecasting*(1ra Edición)

Bruce L. B., Richard T.(2007) O´Connell, Anne B. Koehler, “*Pronósticos, series de tiempo y regresión*”, Cuarta Edición. CeagageLearning.

Carrasco D. S, (2009)“*Metodología de la Investigación Científica*”, Primera Edición, Editorial San Marcos.

Doepke, M, (2013). “*Exploitation, Altruism, and Social Welfare: An Economic Exploration*”.

Hanke, J. y Ritsch, A. (1996). “*Pronósticos en los negocios*”.(5ta Edición) México, Editorial Prentice Hell Hispanoamérica S.A.

Uriel J. E.. *Análisis de series temporales* (1985). Editorial Paraninfo S.A. Madrid-España.

Zavala T. S. (2009) “*Guía a la redacción en el estilo APA*”, 6ta edición.

Bossio, J. C. (2007) *“Mortalidad por Enfermedades Respiratorias en Menores de 5 Años en Argentina. 1980-2005”*.

Colina E. y Rivas F. (1998) *Introducción a la inteligencia artificial*. Mérida Venezuela : Universidad de los Andes.

Faraway J. y Chatfield C. (1998) *Time series forecasting with neural networks: a comparative study using the airline data. Applied Statistic*.

Benedetti F., Baigún A. y Yanguas M. *“Predicciones de Series de Tiempo con Redes Neuronales: Trading usando el Índice Merval”*

Morales A. y Cruz I. *“Pronósticos mediante redes neuronales artificiales y modelos ARIMA”* Mexico

TESIS DE CONSULTA

Coasaca Y.(2010) *“Modelo univariante de predicción de consumo de energía eléctrica para el servicio eléctrico de llave – electro Puno, periodo 2000 – 2009”*

Huacantara K. (2010) *“Modelo uniecuacional para describir y predecir el comportamiento de los niveles medios de agua del lago Titicaca, periodo 1984 – 2008, Puno”*

Mollinedo Y. (2010) *“Modelos de series de tiempo para el pronóstico de temperaturas ambientales mínimas en el distrito de puno periodo 2000 – 2009, Puno”*

Quispe J. (2012) *“Modelo de predicción de los nacimientos y defunciones del distrito de juliaca-2012”*

Melo E. (2016) *“Modelo de predicción mensual de mortalidad general intrahospitalaria en el hospital regional Manuel Núñez Butrón, Puno 2008-2016 I”*

Merlin W. (2015) *“Modelo univariante de pronóstico del número de unidades de transfusión de sangre en el hospital regional Manuel Núñez Butrón, Puno periodo 2006-2015 I”*

REFERENCIA ELECTRÓNICA

Análisis de Series de Tiempo: <https://seh-/e/ha/series.html>

Metodología de Box Jenkins: <https://uva.es/consultas/guia.php?AppliedTimeSeriesandBox-JenkinsModels>.

Mortalidad infantil, disponible en: https://en.wikipedia.org/wiki/Anita_Hill

Proceso estocástico: <https://seh-/e/ha/series.html>

Serie temporal <http://seh-/e/ha/series.html>

Aplicación de Redes Neuronales en la Predicción:
<https://www.youtube.com/watch?v=02LyuOZfGLw>

Predicción de Series Temporales usando RN:
<http://www.bcu.gub.uy/Comunicaciones/Jornadas%20de%20Economia/ies03j3350807.pdf>

ANEXO 1

Variable: WORKAREA.FORECASTS (length = 24 3)

(1,1)	2.259	(1,2)	-0.507532	(1,3)	5.02552
(2,1)	0.697693	(2,2)	-2.07026	(2,3)	3.46564
(3,1)	1.33267	(3,2)	-1.4367	(3,3)	4.10203
(4,1)	0.462759	(4,2)	-2.30803	(4,3)	3.23354
(5,1)	1.77885	(5,2)	-0.99335	(5,3)	4.55105
(6,1)	1.49796	(6,2)	-1.27565	(6,3)	4.27158
(7,1)	2.92709	(7,2)	0.152056	(7,3)	5.70212
(8,1)	1.79993	(8,2)	-0.976523	(8,3)	4.57637
(9,1)	1.89463	(9,2)	-0.883236	(9,3)	4.67249
(10,1)	0.563355	(10,2)	-2.21592	(10,3)	3.34263
(11,1)	0.235342	(11,2)	-2.54535	(11,3)	3.01603
(12,1)	0.0687621	(12,2)	-2.71334	(12,3)	2.85086
(13,1)	2.04594	(13,2)	-0.974554	(13,3)	5.06644
(14,1)	0.48464	(14,2)	-2.53838	(14,3)	3.50766
(15,1)	1.11961	(15,2)	-1.90593	(15,3)	4.14515
(16,1)	0.249706	(16,2)	-2.77835	(16,3)	3.27777
(17,1)	1.5658	(17,2)	-1.46478	(17,3)	4.59637
(18,1)	1.28491	(18,2)	-1.74818	(18,3)	4.318
(19,1)	2.71404	(19,2)	-0.321564	(19,3)	5.74964
(20,1)	1.58687	(20,2)	-1.45124	(20,3)	4.62498
(21,1)	1.68157	(21,2)	-1.35904	(21,3)	4.72219
(22,1)	0.350302	(22,2)	-2.69282	(22,3)	3.39343
(23,1)	0.0222895	(23,2)	-3.02334	(23,3)	3.06792
(24,1)	-0.144291	(24,2)	-3.19242	(24,3)	2.90384

Variable: WORKAREA.RESIDS (length = 108)

(1) (19) -1.02809 (37) 2.68993 (55) -0.82414
 (2) (20) -1.99516 (38) 0.578986 (56) -0.259851
 (3) (21) -0.931237 (39) 0.823772 (57) 2.97202
 (4) (22) 0.0985971 (40) -0.704526 (58) 0.707248
 (5) (23) -0.904562 (41) -2.78695 (59) 1.72438
 (6) (24) -0.875582 (42) 1.06376 (60) -4.33086
 (7) (25) -0.847531 (43) -0.124842 (61) -1.5395
 (8) (26) 0.786525 (44) -0.882271 (62) 1.97785
 (9) (27) -0.452481 (45) -0.485673 (63) 0.618381
 (10) (28) 0.382727 (46) 0.898218 (64) 0.259177
 (11) (29) -1.45025 (47) -0.712698 (65) 1.86863
 (12) (30) -1.79688 (48) -0.689865 (66) 2.1597
 (13) (31) -0.346218 (49) -1.24015 (67) -0.514025
 (14) 1 (32) 0.0579704 (50) -0.429255 (68) 3.82889
 (15) -1.03204 (33) 0.663017 (51) 0.744316 (69) -1.3374
 (16) 2.00103 (34) 1.24868 (52) 1.80896 (70) -0.611262
 (17) -1.06308 (35) -1.39823 (53) -0.526526 (71) -0.960625
 (18) -0.0290226 (36) -1.35343 (54) -3.22683 (72) -1.57127
 (73) 0.0889504 (91) -0.80317
 (74) -0.809144 (92) -0.432196
 (75) 1.43017 (93) 0.972249
 (76) 1.17837 (94) 0.192779
 (77) -2.87756 (95) 1.65761
 (78) -0.572382 (96) -1.23865
 (79) -0.134749 (97) 0.787098
 (80) -4.5047 (98) 0.0390378

(81) -0.421371 (99) 0.639243
(82) 6.81962E-3 (100) -1.2433
(83) 0.782687 (101) -0.0765862
(84) -0.63167 (102) -1.25902
(85) -0.634389 (103) -0.278051
(86) -0.157392 (104) -0.0596141
(87) -0.809034 (105) -0.213745
(88) 1.09188 (106) 0.338943
(89) -0.381752 (107) -0.779154
(90) 0.973547 (108) -0.479717
