

DEMANDA DE TURISMO INTERNACIONAL EN TIEMPOS DE COVID-19 EN LA REGIÓN DE PUNO- PERÚ

DEMAND FOR INTERNATIONAL TOURISM IN TIMES OF COVID-19 IN THE PUNO-PERU REGION

Luis Francisco Laurente Blanco ^P

- **RESUMEN:** La industria del turismo es de importancia en la región de Puno pues de ella se benefician cientos de personas. Sin embargo, ante la medida de aislamiento social producto de la pandemia mundial del COVID-19, este sector de la economía se perjudicó drásticamente ya que para el segundo trimestre de 2020 el total de arribos cayó en 100%. En este sentido es necesario conocer los arribos futuros ante ausencia de la pandemia para la estimación de las pérdidas y estrategias de reactivación. El objetivo del trabajo es conocer el comportamiento de la demanda de turismo internacional en la región de Puno y proyectarla a futuro haciendo uso de modelos de series de tiempo con información mensual del período 2003 a 2019. Los resultados de la investigación revelaron que el modelo $SARIMA(6, 1, 24)(1, 0, 1)_{12}$ es el de mayor eficiencia para el modelamiento y proyección del turismo en Puno.
- **PALABRAS CLAVE:** Estacionalidad del turismo, lago Titicaca, turismo en el Perú, modelos $ARIMA$, aislamiento social.
- **ABSTRACT:** The tourism industry is important in the Puno region as hundreds of people benefit from it. However, in the face of the measure of social isolation resulting from the global pandemic of COVID-19, this sector of the economy was drastically damaged, since for the second quarter of 2020 the total arrivals fell by 100%. In this sense, it is necessary to know the future arrivals in the absence of the pandemic to estimate the losses and reactivation strategies. The objective of the work is to know the

^P Facultad de Ingeniería Económica de la Universidad Nacional del Altiplano, Perú (UNAP) y Centro de Investigaciones en Ciencias y Análisis Económico (CIAE). Email: flaurenteblanco@gmail.com

Economía coyuntural, Revista de temas de coyuntura y perspectivas, ISSN 2415-0630 (en línea) ISSN 2415-0622 (impresa), vol. 6 n°1, 49-78, ene-mar 2021.

behavior of the demand for international tourism in the Puno region and forecast it into the future using time series models with monthly information from the period 2003 to 2019. The results of the investigation revealed that the $SARIMA(6,1,24)(1,0,1)_{12}$ model is the most efficient for the modeling and forecasting of tourism in Puno.

- **KEY WORDS:** Seasonality of tourism, Lake Titicaca, tourism in Peru, *ARIMA* models, social isolation.
- **CLASIFICACIÓN JEL:** C21, M21, Z32.
- Recepción: 30/09/2020 Aceptación: 18/02/2021

INTRODUCCIÓN

Disponer de un conocimiento preciso de la evolución de la tasa de inflación es una actividad clave a la que se enfrentan los bancos centrales y hacedores de política económica, debido a que el efecto de las políticas monetarias solo afecta a la evolución dinámica de los precios con un considerable retardo de tiempo. La discusión y el análisis comparativo de diferentes procedimientos para explicar y mejorar las variables que influyen en la explicación y la predicción de la inflación han adquirido una especial relevancia en las últimas décadas. De forma general, el debate se ha centrado en los siguientes puntos fundamentales. El 31 de diciembre de 2019 se identificaron los primeros casos de una neumonía de origen desconocido en Wuhan (China). El patógeno era un nuevo betacoronavirus de ARN del síndrome respiratorio severo SARS-COV-2 llamado posteriormente como COVID-19 (OMS, 2020). A finales de enero de 2020 se reportaron cerca de 80 mil casos y más de 3 mil muertes en China por lo que la Organización Mundial de la Salud (OMS) declaró el brote SARS-COV-2 como una Emergencia de Salud Pública de Importancia Internacional. La velocidad de contagio del virus hizo que la OMS declare la pandemia global el 11 de marzo del 2020 (OPS, 2020). En este sentido, esta

alarma general hizo que el Estado peruano se vea obligado a tomar medidas drásticas para frenar el avance de esta pandemia (PERU, 2020); es así que el 16 de marzo comienza el Estado de Emergencia en el Perú que incluía un cierre de fronteras para transporte de pasajeros e inamovilidad nacional entrando el país en un estado de cuarentena y aislamiento social obligatorio. Esta medida afectó severamente a todas las actividades económicas en especial a la actividad turística pues la contribución del turismo al PBI para el segundo trimestre del año 2020 cayó en 100% en todo el país; es decir, desaparece por completo la actividad turística en las regiones del Perú como consecuencia de las restricciones globales al movimiento de personas. Para el caso de la región Puno, esta medida de aislamiento social obligatorio, trajo un impacto negativo al mercado laboral y una incertidumbre para los empleados del sector formal relacionados directa e indirectamente a la actividad del turismo (RPP, 2020) debido que este sector de la economía es de mucha importancia, pues al ser Puno la décima región más pobre del Perú con una tasa de pobreza cercana al 24% (INEI, 2018), es una economía muy dependiente del sector turismo ya que genera más de 90 mil puestos de trabajo directo e indirecto. En este sentido es de importancia conocer el número de arribo de turistas internacionales que hubieran llegado a la región en ausencia de la pandemia para realizar la previsión de los ingresos que se dejaron de percibir y el cálculo de pérdidas sobre el número de arribos y en seguida, trabajar las diversas estrategias de reactivación de esta industria.

El objetivo de esta investigación es conocer el comportamiento de la demanda de turismo internacional en la región de Puno y proyectarla a futuro para realizar un balance entre el ambiente de aislamiento social debido a la pandemia COVID-19 y un escenario normal sin aislamiento que permita realizar la previsión y trabajar en la reactivación de este sector para minimizar

las pérdidas ocurridas por causa del aislamiento social. Para este fin, se hace uso de un análisis de serie temporal de los arribos con periodicidad mensual de los años 2003 a 2019. Para la estimación de los modelos econométricos se utiliza los modelos autorregresivos y medias móviles *ARIMA* planteadas por Box & Jenkins (1976). El documento se estructura de la siguiente manera. En la sección dos se presenta una revisión de la literatura haciendo hincapié a las metodologías de modelamiento y proyección aplicados al turismo. En la sección tres se muestran los materiales y métodos, donde se describe la información estadística y la metodología de estimación. En la sección cuatro se presenta los resultados más resaltantes del trabajo. En esta sección se da una explicación al procedimiento para hallar el modelo de eficiencia para el arribo de turistas a Puno siguiendo de cerca el trabajo de Laurente & Machaca (2020) y ampliando la discusión para tiempos de aislamiento social debido a la pandemia COVID-19 mediante un balance entre la proyección del modelo de turismo reportado y la situación actual de la demanda por turismo. Finalmente, en la sección cinco se presentan las principales conclusiones del estudio que servirán para conocer el comportamiento del turismo y para prever las estrategias de reactivación tras el aislamiento social.

2. REVISIÓN DE LITERATURA

Para la realización de los modelos de pronóstico del sector turismo existen diversos trabajos de investigación a nivel internacional que utilizan la familia de modelos *ARIMA*. En este sentido se señalan los trabajos de Choden & Unhapipat (2018), Msofe & Mbago (2019), Makoni & Chikobvu (2018), Petrevska (2017) y Kulendran & Wong (2005) que utilizan el modelamiento *ARIMA* para el sector turismo. Los trabajos de Chhorn & Chaiboonsri (2017), Borhan & Arsad (2014), Ying-Fang et al., (2014), Uwilingiyimana et al., (2016) y Jiménez et al., (2006) utilizan los modelos *ARIMA/GARCH* de turismo. Por

su parte, Chokethaworn et al., (2010), Flores-Muñoz et al., (2019), Al-Shboul & Anwar (2017), Castaño (2016) y Aladag et al., (2012) utilizan los modelos *ARFIMA* o llamados también modelos de series de tiempo con memoria larga para el modelamiento del turismo internacional. Para medir la eficiencia de los modelos de series de tiempo dentro de un grupo de modelos de estimación; los trabajos de Mishra et al., (2018) y Lee et al., (2008) realizan la construcción de los estadísticos MAPE, MAE y RMSE. Chokethaworn et al., (2010) y Ray (1993) utilizan modelos *ARFIMA/FIGARCH* para el modelamiento del turismo y con modelamiento *X12/ARIMA/ARFIMA* el trabajo de Chaitip & Chaiboonsri (2015). En el mismo contexto, Akal (2004) y García (2017) utiliza los modelos *ARMAX* para la proyección del turismo; y Laurente & Machaca (2020), Mishra et al., (2018) y Peiris (2016) utilizan la metodología *SARIMA* para el modelamiento y proyección de la demanda de turismo. Respecto a los modelos de riesgo VaR aplicados al sector turismo, Pérez-Rodríguez & Santana-Gallego (2020) utilizan para sus aproximaciones.

3. MATERIALES Y MÉTODOS

En esta sección se presenta lo siguiente: la descripción de los datos que se utilizan en la estimación, el desarrollo de la metodología *ARIMA* y las pruebas estadísticas utilizadas para la evaluación de los modelos estimados.

3.1. Datos

Los datos empleados en la presente investigación consta de información mensual de los arribos de turistas internacionales a la región Puno para el período 2003 a 2019. Esta información estadística se adquirió de la página web del Banco Central de Reserva (BCRP, 2020) en un total de 204 observaciones.

3.2. Metodología *ARIMA*

Box & Jenkins (1976) plantea el modelamiento *ARIMA* o en español denominado como el modelo autorregresivo de medias móviles que consiste en el análisis de series temporales permitiendo conocer la ecuación de comportamiento para su futuro tratamiento. Esta puede ser estacional, de baja frecuencia, de alta frecuencia, entre otros según la naturaleza de la serie de tiempo. Como se señaló en la sección anterior, existen diversos trabajos de estimación que emplean los modelos *ARIMA* para el modelamiento y proyección del turismo pues son muy eficientes. Los pasos de la esta metodología se organizan de la siguiente manera. En primer lugar se realiza el análisis preliminar de la información. En este paso inicial se realiza el análisis preliminar a toda la información disponible con la finalidad que la información se comporte como un proceso estacionario; en este sentido, se emplea la inspección visual del comportamiento de la serie, su evolución, sus posibles quiebres, su volatilidad, entre otros. En segundo lugar, se identifica el orden (p, d, q) del modelo *ARIMA* donde se hace uso de la existencia de raíz unitaria para determinar el orden de integración d ; y de los estadísticos de Correlograma y funciones de correlación (parcial y simple) para la determinación más precisa del orden autorregresivo (p) y de medias móviles (q) . En tercer lugar se realiza la estimación de los modelos autorregresivos del paso anterior. Esta estimación se puede hacer mediante mínimos cuadrados ordinario (*lest squared*) o máxima verosimilitud (*loglikelihood*). En cuarto lugar, se realiza la selección de los modelos estimados del paso anterior y el diagnóstico de los resultados. Para la selección del modelo de mayor ajuste se emplea el criterio de información de Akaike (AIC) y el criterio de Schwarz (SC), seleccionándose aquel que posea el mínimo valor de estas pruebas. Por otro lado, para verificar el ajuste de un modelo de eficiencia se utiliza los

estadísticos: MAPE (media porcentual del error), Z (porcentaje de resultado), y el estadístico r de correlación. En la selección se toma aquel modelo que cuenta con el menor valor del estadístico MAPE y el menor valor de los estadísticos Z y r de correlación. Finalmente, en quinto lugar el modelo *ARIMA* seleccionado puede ser usado para proyección de la demanda del turismo. Este modelo se asume que es el de mayor ajuste y eficiencia dentro del grupo de modelos estimados.

Para el modelado *ARIMA* de turismo internacional se define el proceso autorregresivo *AR(p)* de orden *p* y el proceso de medias móviles *MA(q)* de orden *q* siguientes:

$$AR(p): \text{arribos}_t = \sum_{i=1}^p \phi_i \text{arribos}_{t-i} + \varepsilon_t,$$

$$MA(q): \text{arribos}_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}.$$

donde arribos_t es el número total de visitas de turistas internacionales a Puno en el período t . El valor p y q es el valor óptimo de retardo en el proceso *AR* y *MA*, respectivamente. Los valores $\phi_i, i = 1, \dots, p$ son los parámetros que indican el efecto de la variable retardada $\text{arribos}_{t-i}, i = 1, \dots, p$ sobre la realización presente, y los valores $\theta_i, i = 1, \dots, q$ son los efectos de los errores retardados $\varepsilon_{t-i}, i = 1, \dots, q$ sobre la realización presente. La formulación general de un modelo *ARIMA(p, d, q)* para el turismo se denomina *proceso integrado de medias móviles* de orden (p, d, q) y escribimos como

$$\Delta^d \text{arribos}_t = \text{arribos}_t - \text{arribos}_{t-d} = \sum_{i=1}^p \phi_i \text{arribos}_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}, \quad (1)$$

donde el valor d representa el orden de integración del modelo, es decir, el número de veces que necesita diferenciarse para convertirse en un proceso estacionario $I(0)$ o de ruido blanco. La ecuación (1) también se puede expresar en su forma compacta,

$$\begin{aligned} & (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)(1 - L)^d \text{arribos}_t \\ & = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t. \end{aligned}$$

donde L es el operador de retardo. Si el modelo *ARIMA* es un modelo que captura estacionalidad, esta se puede representar como *SARIMA*(p, d, q)(P, D, Q), donde el primer paréntesis (p, d, q) señala al proceso autorregresivo de tendencia secular o de parte regular y el segundo paréntesis (P, D, Q) señala a las variaciones estacionales o cíclicas de la serie temporal.

3.3. Tests de significancia y de selección del modelo óptimo de turismo

Para determinar el orden de integración d del modelo *ARIMA* es necesario realizar pruebas de raíz unitaria a la variable de series de tiempo. Como se indicó, el orden de integración identificado permitirá convertir una serie no estacionaria a una estacionaria después de diferenciarla d veces. Para llegar a este objetivo, utilizaremos tres estadísticos de raíz unitaria que son muy utilizados en la ciencia económica y están respaldados por investigaciones empíricas que las utilizan. Los tests descritos son: la prueba de Dickey & Fuller (1979) aumentada (ADF), la prueba PP de Phillips & Perron (1988) y la prueba

KPSS de Kwiatkowski, Phillips, Schmidt, & Shin (1992) de KPSS. La hipótesis nula H_0 de la prueba ADF es la existencia de raíz unitaria en la variable temporal. En este contexto, dado un proceso autorregresivo de primer orden para el turismo $AR(1): arribos_t = \rho arribos_{t-1} + \mu_t$ con la variable temporal $arribos_t$ que describe los arribos internacionales de turistas en el período t , ρ es un coeficiente, y μ_t es el término de error, la existencia de raíz unitaria $I(1)$ se da cuando el valor $\rho = 1$, lo que indica que la serie no es estacionaria y tiene un orden de integración $I(1)$, lo que es lo mismo, que la serie necesita el cálculo en su primera diferencia para convertirse en un proceso $I(0)$ o estacionaria. Por lo tanto, el modelo de regresión para el turismo se modifica en términos de primera diferencia a la forma $\Delta arribos_t = (\rho - 1)arribos_{t-1} + \mu_t = \delta arribos_{t-1} + \mu_t$ donde Δ es el operador de primera diferencia relacionado a $I(1)$. Este modelo puede ser estimado y la prueba para verificar la existencia de una raíz unitaria es equivalente a un valor $\delta = 0$ (donde $\delta = \rho - 1$). Dado que la prueba ADF se estima a partir de los residuos de un modelo original, la utilización de la distribución Gaussiana estandarizada generaría una subestimación (o sobreestimación) del comportamiento normal de los errores; es por ello que la prueba ADF viene incorporada con una tabla de probabilidad dada en Dickey & Fuller (1979). Por otra parte, la prueba de raíz unitaria PP de Phillips & Perron (1988) se utiliza en el análisis de series de tiempo para contrastar la hipótesis nula de estacionariedad que es similar a la prueba ADF.

Para la selección de modelos óptimos hacemos uso del Criterio de Información de Akaike (AIC) desarrollado por Akaike (1974) y el Criterio de Schwarz (BIC) formulado por Schwarz (1978). Ambos estadísticos es una medida para la selección del modelo óptimo. Para el caso general del estadístico de Akaike se tienen: $AIC = 2k - 2 \ln(L)$, donde k es el número

de parámetros en el modelo y L es el valor de la función de máxima verosimilitud en el modelo. Por otra parte, la prueba BIC es un criterio para elección de modelos dentro de un grupo de modelos con diferente número de parámetros. Esta prueba estadística se escribe en modo general como $-2 \ln p(x|k) \approx \text{BIC} = -2 \ln(l)$, donde n es el tamaño de la muestra empleada, k es el número de parámetros que incluye la constante y L es el valor máximo de la función de verosimilitud. El criterio de decisión para ambos modelos cuando se tiene un grupo de modelos estimados es tomar aquel modelo que presente los menores valores de ambas pruebas. Los criterios AIC y SBIC son seleccionados para algún modelo que cuente con los menores valores de estos.

Por otro lado, diversos estudios de modelamiento y proyección utilizan estadísticos que miden la eficiencia dentro de un conjunto de modelos. Estos estadísticos son calculados con la finalidad de conocer cuánto es el desbalance entre la variable observada y la variable proyectada. A diferencia de las pruebas AIC y SBIC, estos estadísticos de eficiencia se basan en la información actual y proyectada de la variable de estudio, mientras que SBIC y AIC se basan en la información del modelo estimado, como por ejemplo sula función L de verosimilitud, su error estándar y los valores de los coeficientes del modelo estimado. Los modelos de eficiencia mencionados son: la prueba MAPE o media ponderada del error; el estadístico Z de medida del resultado; y el coeficiente r de correlación normalizada. La prueba MAPE es una medida de la serie temporal y se expresa en porcentajes. Su fórmula matemática para el arribo de turistas es la siguiente:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\text{arribos}_i - \text{arribos}_f_i}{\text{arribos}_i} \right| * 100\%$$

donde $arribos_i$ es el valor actual de los arribos de los turistas internacionales y $arribosf_i$ es el valor de proyección de la misma serie para las observaciones $i = 1, \dots, n$. El estadístico MAPE es adimensional, donde al multiplicarse por 100% nos muestra un valor de porcentaje donde Lewis (1982) señala una clasificación por intervalos del estadístico. Así si el valor de MAPE es inferior al 10% se considera que el modelo es un pronóstico de alta precisión; si el estadístico se encuentra entre el 10-20% se considera que el modelo tiene un pronóstico bueno. Además, si el valor de MAPE está entre 20-50% se considera un pronóstico razonable; y si el estadístico es mayor al 50% se asume que el modelo objeto de estudio posee un pronóstico inexacto. En este sentido, es lógico la aceptación del estadístico cuanto menor sea y si se compara entre dos o más modelos se debería elegir aquel que presente el menor MAPE para considerarse más eficiente que los otros modelos objetos de comparación. Análogamente, el estadístico Z se usa como una medida relativa y para su análisis es recomendable compararla con un valor de 5%. En este sentido, el estadístico Z para la variable $arribos_i$ queda definida como:

$$Z = \frac{\sum_{i=1}^n j}{n} * 100\% \text{ para } \begin{cases} j = 1 \text{ si } \left| \frac{arribos_i - arribosf_i}{arribos_i} \right| < 0.05, \\ j = 0 \text{ si otro caso.} \end{cases}$$

Para la selección del modelo de eficiencia se debe considerar aquel que cuente con el mayor valor de Z. Similarmente, el estadístico de ajuste para modelo de eficiencia es el estadístico r de correlación normalizado. Para el caso del turismo, el estadístico r queda definido como:

$$r = \frac{\sum_{i=1}^n arribos_i * arribosf_i}{\sqrt{\sum_{i=1}^n arribos_i^2 * \sum_{i=1}^n arribosf_i^2}}$$

En la selección del mejor modelo de eficiencia se opta por seleccionar aquel modelo cuyo estadístico r sea el mayor.

4. RESULTADOS

Esta sección del documento presenta el desarrollo de la estimación de los modelos autoregresivos *ARIMA* Box & Jenkins (1976) y su aplicación a la demanda del turismo internacional a Puno. Dándole un orden a los resultados se considera en primer lugar la identificación de los modelos autorregresivos presentando para tal fin las estadísticas descriptivas, el comportamiento gráfico y las pruebas de raíz unitaria aplicada a la variable de estudio. En segundo lugar, se presenta la estimación de los modelos de mayor ajuste de arribo de turistas y la selección del modelo de eficiencia. En tercer lugar, se presenta el cálculo para el modelo de eficiencia dentro del grupo de modelos y su selección. EN cuarto lugar, se presenta el examen de diagnóstico al modelo seleccionado de eficiencia, finalmente se presenta la proyección a 18 meses de los arribos de turistas y se hace un balance entre un período normal y un período de aislamiento social por causa de la pandemia COVID-19.

Para el procesamiento de la información se hizo uso del software econométrico Eviews 9[®], con un total de 204 observaciones mensuales del arribo de turistas internacionales a la región de Puno para el período 2003-2019. De esta información se tiene una media de 20,018 arribos de turistas; un mínimo de 4,650 arribos; y un máximo de 36,147 para el período indicado. Estos resultados se muestran en la Tabla 1.


Tabla 1: Estadística descriptiva

Lista de variables	Abreviatura	Obs.	Media	Desv. Estánd.	Mínimo	Máximo
Arribo de turistas internacionales a Puno	<i>arribos</i>	204	20,018	8,860	4,650	42,716


Fuente: Elaboración propia

En la identificación del comportamiento de los arribos de turistas, la Figura 1(a) presenta la evolución del arribo mensual y el arribo por estaciones. De la figura se observa que la serie temporal tiene un comportamiento creciente y clasificándola por estaciones se observa de la Figura 1(b) que posiblemente haya un comportamiento estacional con un máximo de arribos en el mes de agosto y una disminución en el mes de diciembre.

Figura 1: Arribo mensual de turistas internacionales a Puno, 2003-2019



(a) Arribo mensual



(b) Arribo por estaciones

Fuente: Elaboración propia

Para el análisis de estacionariedad se utilizó las pruebas de raíz unitaria ADF, PP y KPSS mostradas en la Tabla 2. En los resultados de los *tests* evaluados en niveles se reportan que el arribo de turistas no es estacionaria al 1% de significancia lo que evidencia la existencia de una raíz unitaria. Seguidamente, realizando el cálculo de la serie en primeras diferencias se observa de los *tests* que la serie presenta estacionariedad al 1% de significancia, lo que indica que la serie es integrada de orden $I(1)$ o estacionaria en primera diferencia. Como consecuencia de los resultados de los *tests* de estacionariedad, se afirma que la ecuación (1) tiene un valor en el orden de diferenciación $d = 1$. En este sentido la variable dependiente $arribos_t$ será expresada en primera diferencia como $\Delta arribos_t$ donde Δ indica la primera diferencia.

Tabla 2: Pruebas de raíz unitaria

Variable	Ninguno		Con intercepto		Con intercepto y tendencia	
	Nivel	Primera diferencia	Nivel	Primera diferencia	Nivel	Primera diferencia
Test de ADF	0.456 (0.812)	-3.043** (0.003)	-1.465 (0.549)	-3.203* (0.021)	-2.423 (0.366)	-3.243* (0.079)
Test de PP	-0.820 (0.359)	-20.126** (0.000)	-4.022** (0.002)	-20.175** (0.000)	-6.378** (0.000)	-20.173** (0.000)
Test de KPSS	-- --	-- --	1.758 (0.739)~	0.122** (0.463)~	0.143* (0.216)~	0.051** (0.216)~

Notas: *Describe significancia estadística al 5% de significancia. **Describe significancia estadística al 1% de significancia. () Indica el *p-value* de Mackinnon (1996) al 5% de significancia estadística. ~ Indica el valor crítico asintótico al 1% para la prueba de KPSS de Kwiatkowski et al., (1992).

Fuente: Elaboración propia

La estimación de modelos *ARIMA* se muestra en la Tabla 3 donde la información de arribo de turistas se encuentra en base logarítmica. En las estimaciones de la tabla se utilizaron los estadísticos FAS/FAP de autocorrelación simple y parcial para verificar el orden adecuado del proceso AR/MA. Seguidamente, se seleccionaron los cuatro mejores modelos de un grupo de combinaciones de modelos según los estadísticos FAS/FAP y AIC/SC. Para la estimación se hace uso de la metodología de mínimos cuadrados. De estos resultados de la tabla se observa que estos modelos de mejor ajuste no presentan problemas de autocorrelación ya que el estadístico DW se encuentra cerca de 2 como lo indica (Durbin & Watson, 1950). Luego, en la selección del mejor modelo, se observa que el Modelo 1 presenta los menores valores de AIC y SBIC, lo que conlleva la aceptación del Modelo 1 como el modelo de mayor ajuste dentro del grupo de modelos estimados. El Modelo 1 seleccionado es el modelo *SARIMA*(6, 1, 24)(1, 0, 1)₁₂ útil para

representar a los arribos de turistas internacionales que visitan Puno en el período 2003-2019. Los resultados encontrados del modelo de mayor ajuste respecto de los arribos de turistas internacionales son similares a lo encontrado por Laurente & Machaca (2020) quienes trabajan el modelamiento en un escenario de intervención considerando la crisis financiera internacional y un segundo escenario libre de intervención.

Tabla 3: Modelos *ARIMA* para arribos de turistas internacionales a Puno

Variable	Coefficiente	t-Statistic	AIC/SBIC	DW	
Modelo 1					
<i>constante</i>	0.006153	2.228600			
<i>AR(1)</i>	0.479268	4.403580			
<i>AR(3)</i>	0.217050	2.470416			
<i>AR(6)</i>	-0.153538	-2.350674	AIC = -1.233120	2.037750	
<i>SAR(12)</i>	0.985803	149.813000	SBIC = -1.086229		
<i>MA(1)</i>	-0.909474	-7.543715			
<i>MA(24)</i>	-0.089658	-2.235825			
<i>SMA(12)</i>	0.013806	13.176410			
Modelo 2					
<i>constante</i>	0.006095	2.192491			
<i>AR(24)</i>	0.737995	14.470560			
<i>MA(1)</i>	-0.452179	-5.467121	AIC = -1.056130	2.029174	
<i>MA(2)</i>	-0.160793	-2.014071	SBIC = -0.925561		
<i>MA(6)</i>	-0.243845	-3.230278			
<i>MA(25)</i>	-0.143183	-1.999761			
<i>SMA(12)</i>	0.739738	14.695220			
Modelo 3					
<i>constante</i>	0.005758	1.447469			
<i>AR(7)</i>	-0.221618	-2.895774			
<i>MA(1)</i>	-0.296425	-4.259616			
<i>MA(2)</i>	-0.164090	-2.271024	AIC = -0.793838	2.152267	
<i>MA(8)</i>	-0.291198	-5.300864	SBIC = -0.630626		
<i>MA(17)</i>	-0.183246	-2.539064			
<i>MA(20)</i>	-0.173945	-2.457093			
<i>MA(24)</i>	0.382207	5.963004			
<i>SMA(12)</i>	0.611510	10.042810			

Modelo 4

<i>constante</i>	0.005980	1.053801		
<i>MA(1)</i>	-0.239321	-3.800742		
<i>MA(2)</i>	-0.219142	-3.191971		
<i>MA(8)</i>	-0.283379	-5.266428	AIC = -0.759658	
<i>MA(17)</i>	-0.230056	-3.518288	SBIC = -0.612767	2.209683
<i>MA(20)</i>	-0.126076	-1.818725		
<i>MA(24)</i>	0.409461	6.377352		
<i>SMA(12)</i>	0.622917	10.449230		

Notas: El estadístico de Durbin-Watson de autocorrelación se representa por DW. Todas las variables incluidas resultan ser significativas al 1% de significancia. Para la estimación se utilizan los estadísticos FAS y FAP de autocorrelación simple y parcial, respectivamente.

Fuente: Elaboración propia

En seguida, para evaluar la eficiencia en la selección de modelos de la Tabla 3 presenta líneas arriba, la Tabla 4 presenta una comparación de los modelos *ARIMA* mostrando los estadísticos de eficiencia MAPE, Z y r para los cuatro modelos de estimación. Los resultados muestran que el Modelo 1 o *SARIMA(6, 1, 24)(1, 0, 1)₁₂* es el modelo más eficiente de los modelos presentados debido que presenta un valor de MAPE igual a 0.85% menor al 10% como regla de decisión, lo que señala que este modelo es altamente preciso. Luego, por ubicarse este modelo con un valor MAPE inferior a los otros modelos de eficiencia, es claro su elección. Similarmente, para el Modelo 1 el estadístico Z es igual a 11.35 que es el mayor valor de este estadístico dentro del conjunto de modelos, lo que indica que el modelo indicado es el más eficiente. Similar resultado se observa con el estadístico de correlación normalizado r que es igual a 0.89 para el Modelo 1, siendo el mayor dentro del grupo de modelos, la conclusión es la misma que las pruebas señaladas. En efecto, el Modelo 1 dado por *SARIMA(6, 1, 24)(1, 0, 1)₁₂* es el modelo de mayor ajuste (según los menores valores de AIC y SC) y el más eficiente (según MAPE, Z y r) dentro del grupo de modelos estimados para la representación de la demanda internacional de turismo en la región de Puno.

Tabla 4: Comparación de los modelos *SARIMA* modelos para la demanda de turismo internacional en Puno

	Modelos	MAPE	Z	r
Modelo 1*	<i>SARIMA</i> (6, 1, 24)(1, 0, 1) ₁₂	0.859*	11.351*	0.890*
Modelo 2	<i>SARIMA</i> (24, 1, 25)(0, 0, 1) ₁₂	1.281	6.704	0.856
Modelo 3	<i>SARIMA</i> (7, 1, 24)(0, 0, 1) ₁₂	1.538	3.571	0.823
Modelo 4	<i>SARIMA</i> (0, 1, 24)(0, 0, 1) ₁₂	1.266	4.926	0.797

Nota: Los estadísticos MAPE, Z y r muestran la eficiencia de los modelos. MAPE está en porcentajes. Z y r en unidades adimensionales. *Indica el modelo seleccionado como el más eficiente por ser el menor de los MAPE y el mayor para los estadísticos Z y r.

Fuente: Elaboración propia

El diagnóstico al modelo *SARIMA*(6, 1, 24)(1, 0, 1)₁₂ se muestra en la Figura 2(a)-(d). En la Figura 2(a) muestra el correlograma Q de Ljung & Box (1978) que indica ausencia de autocorrelación en el modelo pues los valores de los coeficientes caen dentro de los valores de confianza y todos sus valores son estadísticamente significativos, lo que permite señalar que el comportamiento de los errores del modelo se comportan como un proceso de ruido blanco. En la Figura 2(b) se muestra las raíces AR/MA de los polinomios característicos, todos ellos son menores de 1 lo que indica que el modelo *SARIMA* es estable. La Figura 2(c) presenta los valores actuales, proyectados y los residuos del modelo que claramente se puede observar una superposición entre los valores de estimación y de proyección indicando un buen ajuste con la información actual. Para la prueba de normalidad de los errores del modelo seleccionado se utiliza el estadístico de Jarque & Bera (1980) revelada en la Figura 2(d) donde indica el rechazo de la hipótesis de normalidad en el modelo al 5% de significancia. Sin embargo, debido al teorema central del límite, se espera que al aumentar el tamaño de la información con el paso del tiempo, los errores se comporten como una

función normal (Laurente & Poma, 2016). El paso siguiente en la metodología *ARIMA* indica que mediante el modelo seleccionado es posible realizar la proyección al futuro (Box & Jenkins, 1976).

Figura 2: Diagnóstico a los residuos del modelo $ARIMA(6, 1, 24)(1, 0, 1)_{12}$


Sample: 2003M01 2019M12 Included observations: 203 Q-statistic probabilities adjusted for 7 ARMA terms						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.032	-0.032	0.2048	
		2	0.039	0.039	0.5275	
		3	0.019	0.022	0.6065	
		4	0.060	0.059	1.3476	
		5	0.057	0.060	2.0353	
		6	0.006	0.005	2.0429	
		7	0.001	-0.005	2.0432	
		8	-0.046	-0.053	2.4924	0.114
		9	0.023	0.013	2.6108	0.271
		10	0.010	0.011	2.6317	0.452
		11	0.040	0.042	2.9773	0.562
		12	-0.001	0.007	2.9776	0.703
		13	0.057	0.058	3.6827	0.720
		14	0.088	0.089	5.3838	0.613
		15	0.055	0.052	6.0563	0.641
		16	-0.021	-0.034	6.1567	0.724
		17	-0.062	-0.080	7.0141	0.724
		18	0.088	0.067	8.7570	0.644
		19	0.019	0.019	8.8428	0.716
		20	-0.125	-0.135	12.370	0.498
		21	-0.117	-0.123	15.495	0.345
		22	-0.019	-0.014	15.575	0.411
		23	0.035	0.047	15.863	0.463
		24	0.035	0.050	16.153	0.513
		25	-0.056	-0.046	16.891	0.531
		26	0.080	0.097	18.394	0.496
		27	-0.081	-0.079	19.958	0.461
		28	0.058	0.016	20.769	0.473
		29	0.056	0.041	21.507	0.490
		30	0.067	0.085	22.586	0.485
		31	-0.029	-0.008	22.784	0.533
		32	-0.029	-0.040	22.983	0.579
		33	0.011	-0.009	23.013	0.632
		34	-0.052	-0.022	23.676	0.648
		35	-0.098	-0.081	26.069	0.569
		36	-0.077	-0.080	27.535	0.543

(a) Correlograma de los residuos


MA Root(s)	Modulus	Cycle
0.999717	0.999717	
0.942948 ± 0.202948i	0.964541	29.63854
-0.959541	0.959541	
0.959541	0.959541	
-0.479771 ± 0.830987i	0.959541	3.000000
0.479771 ± 0.830987i	0.959541	6.000000
-0.830987 ± 0.479771i	0.959541	2.400000
0.830987 ± 0.479771i	0.959541	12.00000
5.55e-17 ± 0.959541i	0.959541	4.000000
0.832693 ± 0.423259i	0.934091	13.36091
0.679854 ± 0.615458i	0.917055	8.540132
0.487524 ± 0.763430i	0.905817	6.267645
0.266301 ± 0.857336i	0.897742	4.948830
0.030183 ± 0.891187i	0.891698	4.088112
-0.205288 ± 0.863026i	0.887106	3.482289
-0.424379 ± 0.775061i	0.883638	3.032790
-0.612349 ± 0.633527i	0.881095	2.686043
-0.756508 ± 0.448281i	0.879352	2.410438
-0.847102 ± 0.232136i	0.878333	2.186122
-0.877998	0.877998	

AR Root(s)	Modulus	Cycle
-0.864994 ± 0.499405i	0.998809	2.400000
0.864994 ± 0.499405i	0.998809	12.00000
0.499405 ± 0.864994i	0.998809	6.000000
-0.499405 ± 0.864994i	0.998809	3.000000
-3.61e-16 ± 0.998809i	0.998809	4.000000
-0.998809	0.998809	
0.998809	0.998809	
0.763551 ± 0.253998i	0.804690	19.56532
0.011689 ± 0.729126i	0.729220	4.041242
-0.535606 ± 0.398788i	0.667762	2.511680


No root lies outside the unit circle.
ARMA model is stationary.



(b) Raíces inversas de los polinomios AR/MA



(c) Residuos actuales y proyectados




(d) Normalidad de Jarque-Bera


Fuente: Elaboración propia

Al realizar esta práctica, los resultados se muestran en la Figura 3 con la variable *arribos* como variable original y la variable *arribosf* como la variable de proyección del modelo seleccionado. Claramente se ve en la Figura 3(a) que los arribos de turistas no se encuentran muy distantes de los valores proyectados; y en la Figura 4(b) se presenta la proyección a futuro de los arribos de turistas para el período 2020-2021 con una banda superior e inferior al $\pm 2S.E.$ con una significancia del 5%.

Figura 3: Arribo de turistas extranjeros actual y proyectada con modelo $SARIMA(6, 1, 24)(1, 0, 1)_{12}$



(a) Arribo mensual/proyectada 2003-2019



(b) Arribo mensual/proyectada 2020-2021

Fuente: Elaboración propia

En seguida, la Tabla 5 muestra la proyección de la demanda de turistas para el período 2020-2021. Asimismo, la tabla muestra un escenario de arribo de turistas con presencia de aislamiento social causada por la pandemia COVID-19. Además en la tabla se muestra un balance de la diferencia entre ambos escenarios que permite conocer el número de arribo de turistas que dejaron de llegar debido a las medidas de aislamiento social que se vive en la región y en el mundo. En efecto, la segunda columna de la Tabla 5 muestra

los arribos de los turistas en presencia de COVID-19, que el número es de cero desde el mes de marzo de 2020 donde empezó el aislamiento en la región de Puno y el Perú. La tercera columna presenta la proyección de los arribos de turistas usando el modelo *ARIMA* y considerando la ausencia de la pandemia. Esta proyección presenta una banda inferior y superior mostrada en las columnas siguientes. La tabla también presenta un balance para el arribo de turistas que es calculada como la diferencia entre el arribo ante la presencia de COVID-19 y sin ella, respectivamente. De los resultados de la proyección, se observa que para mayo de 2020 dejaron de llegar a Puno un total de 30,470 turistas internacionales; y de no solucionarse el problema de la pandemia, entre los meses de mayo y diciembre de 2020 estarían dejando de llegar cerca de 327,904 turistas internacionales, reflejándose en una pérdida considerable en los ingresos de este sector.

Tabla 5: Demanda de turismo internacional en Puno en tiempos de COVID-19 usando el modelo *SARIMA(6, 1, 24)(1, 0, 1)₁₂*

Mes año	COVID-19	Proyección sin COVID-19		Balance ^d			
	Turistas ^a	Turistas ^b	Inferior ^c	Superior ^c	Turistas	Inferior	Superior
Enero 2020	20,850	19,988	11,167	30,699	862	9,683	-9,849
Febrero 2020	22,185	22,060	12,304	33,907	125	9,881	-11,722
Marzo 2020	0	26,536	14,766	40,827	-26,536	-14,766	-40,827
Abril 2020	0	31,044	17,214	47,839	-31,044	-17,214	-47,839
Mayo 2020	0	30,470	16,872	46,981	-30,470	-16,872	-46,981
Junio 2020	0	28,164	15,583	43,441	-28,164	-15,583	-43,441
Julio 2020	0	36,408	20,043	56,280	-36,408	-20,043	-56,280
Agosto 2020	0	43,238	23,486	67,222	-43,238	-23,486	-67,222
Setiembre 2020	0	36,587	19,894	56,857	-36,587	-19,894	-56,857
Octubre 2020	0	38,167	20,665	59,419	-38,167	-20,665	-59,419

Noviembre 2020	0	36,078	19,487	56,224	-36,078	-19,487	-56,224
Diciembre 2020	0	21,213	11,489	33,021	-21,213	-11,489	-33,021
Enero 2021	0	21,627	11,653	33,739	-21,627	-11,653	-33,739
Febrero 2021	0	23,839	12,822	37,217	-23,839	-12,822	-37,217
Marzo 2021	0	28,603	15,345	44,701	-28,603	-15,345	-44,701
Abril 2021	0	33,391	17,846	52,266	-33,391	-17,846	-52,266
Mayo 2021	0	32,784	17,497	51,347	-32,784	-17,497	-51,347
Junio 2021	0	30,340	16,179	47,535	-30,340	-16,179	-47,535

Notas: ^aValor presente de arribo de turistas internacionales a Puno. ^bValor proyectado de arribo de turistas internacionales a Puno usando $SARIMA(6, 1, 24)(1, 0, 1)_{12}$ ante ausencia de la pandemia COVID-19. ^cBandas construidas al $\pm 2S.E.$ con una significancia del 5%. ^dEl balance está calculado como la diferencia entre los arribos de turistas ante presencia y ausencia de COVID-19, respectivamente.

Fuente: Elaboración propia

5. CONCLUSIONES

En el presente trabajo se presenta la estimación de los modelos *ARIMA* de Box & Jenkins (1976) para la demanda de turismo internacional en la región de Puno-Perú. Se utiliza información mensual de los años 2003 a 2019 extraídos de la página web del BCRP sucursal Puno. Para la selección de modelos eficientes se hace uso del Criterio de Información de Akaike (AIC) y el Criterio de Schwarz (SBIC). Después de una búsqueda de modelos de ajuste univariados *ARIMA*, y utilizando los menores valores AIC y SC, se seleccionó el modelo $SARIMA(6, 1, 24)(1, 0, 1)_{12}$ como el modelo de mayor ajuste dentro de un grupo de modelos para el arribo de turistas internacionales a Puno como en Laurente & Machaca (2020) que reportan un modelo *SARIMA* sin intervención y con intervención de factores externos para Puno. Similarmente, para demostrar la eficiencia de estos modelos seleccionados por AIC y SBIC, se hace uso de las pruebas estadísticas MAPE o medida del error, el estadístico Z, y el estadístico r de correlación normalizado. De los modelos

estimados y evaluados por estos estadísticos, el modelo de eficiencia es el modelo $SARIMA(6, 1, 24)(1, 0, 1)_{12}$ cuyo nivel de pronóstico a la información corriente es el de “altamente preciso”, pues presenta un valor de MAPE igual a 0.85% el mínimo dentro del grupo de modelos estimados. Asimismo, este modelo presenta los valores máximos de Z (igual a 11.35) y el estadístico de correlación normalizado r igual a 0.89 dentro del grupo de modelos de buen ajuste. En seguida, este modelo de eficiencia es utilizado para la proyección del arribo de turistas bajo la presencia de la pandemia COVID-19 que afectó directamente a la demanda de turismo debido que en Puno, como en todo el mundo, el aislamiento social imposibilitó el tránsito y la visita de turistas a los diversos atractivos turísticos. Con esta finalidad, se hizo una proyección a 18 meses (de enero de 2020 a junio de 2021) de la demanda de turistas internacionales a Puno. De estos resultados se considera que para mitad del año 2020, por motivo de COVID-19, hubo una pérdida de 116,213 turistas; y de continuar la restricción por la pandemia, se estima que para fin del año 2020 habrá una pérdida de 327,904 arribos de turistas internacionales. Esta cifra es muy importante en la economía de Puno ya que el sector turismo es una de las actividades económicas más importantes en esta región. Asimismo, el trabajo presenta proyecciones mensuales (y balance) para el año 2021 bajo un escenario de aislamiento por COVID-19 en la región.

Los resultados de la presente investigación son de utilidad para conocer el comportamiento futuro del arribo de turistas y puede ayudar a este sector en tomar una adecuada planificación en términos de pérdida económica y en estrategias de reactivación. Luego, para futuros trabajos se sugiere utilizar la metodología empleada en el presente estudio para hacer el cálculo y proyección de las pérdidas en términos monetarios para el sector turismo en tiempos de pandemia.

AGRADECIMIENTOS

El autor agradece a Dios y al Señor Jesucristo por la guía y bendición en el desarrollo del trabajo. Asimismo, los agradecimientos a los revisores anónimos que contribuyeron con sus aportaciones para la mejora del manuscrito.

REFERENCIAS

- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Akal, M. (2004). Forecasting Turkey's tourism revenues by ARMAX model. *Tourism Management*, 25(5), 565–580. <https://doi.org/10.1016/j.tourman.2003.08.001>
- Al-Shboul, M., & Anwar, S. (2017). Long memory behavior in Singapore's tourism market. *International Journal of Tourism Research*, 19(5), 524–534. <https://doi.org/10.1002/jtr.2125>
- Aladag, C., Egrioglu, E., & Kadilar, C. (2012). Improvement in Forecasting Accuracy Using the Hybrid Model of ARFIMA and Feed Forward Neural Network. *American Journal of Intelligent Systems*, 2(2), 12–17. <https://doi.org/10.5923/j.ajis.20120202.02>
- BCRP. (2020). Síntesis de Actividad Económica de la región de Puno, varios meses. Retrieved May 20, 2020, from <http://www.bcrp.gob.pe/51-sucursales/sede-regional-puno.html>
- Borhan, N., & Arsad, Z. (2014). Forecasting international tourism demand from the US, Japan and South Korea to Malaysia: A SARIMA approach. *AIP Conference Proceedings*, 1605(1), 955–960. <https://doi.org/10.1063/1.4887719>
- Box, G., & Jenkins, G. M. (1976). *Time Series Analysis: forecasting and control*. Oakland, California: Holden-Day.

- Castaño, E. (2016). Identification in ARFIMA models. *Revista de La Facultad de Ciencias Universidad Nacional de Colombia*, 5(1), 12–37. <https://doi.org/10.15446/rev.fac.cienc.v5n1.52890>
- Chaitip, P., & Chaiboonsri, C. (2015). Forecasting with X-12-ARIMA y ARFIMA: International Tourist Arrivals to India. *Annals of the University of Petrosani, Economics*, 9(3), 147–162. Retrieved from <http://repositorio.ana.gob.pe/handle/ANA/1564>
- Chhorn, T., & Chaiboonsri, C. (2017). *Modelling and Forecasting Tourist Arrivals to Cambodia: An Application of ARIMA-GARCH Approach* (MPRA No. 83942). *Munich Personal RePEc Archive Modelling*. <https://doi.org/10.31039/jomeino.2018.2.2.1>
- Choden, C., & Unhapipat, S. (2018). ARIMA model to forecast international tourist visit in Bumthang, Bhutan. *Journal of Physics: Conference Series*, 1039(1), 1–11. <https://doi.org/10.1088/1742-6596/1039/1/012023>
- Chokethaworn, K., Chaiboonsri, C., & Chaitip, P. (2010). International Tourist Arrivals in Thailand: Forecasting With Arfima-Figarch Approach. *Annals of the University of Petrosani, Economics*, 10(2), 75–84.
- Chokethaworn, K., Wiboonponse, A., Sriboonchitta, S., Sriboonjit, J., Chaiboonsri, C., & Chaitip, P. (2010). International Tourists' Expenditures in Thailand: A Modelling of the ARFIMA-FIGARCH Approach. *The Thailand Econometrics Society*, 10(January), 85–98.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, 74(366), 427–431. <https://doi.org/10.2307/2286348>
- Durbin, J., & Watson, G. S. (1950). Testing for Serial Correlation in Least Squares Regression. I. *Biometrika Trust*, 58(1), 409–428. <https://doi.org/10.2307/2332391>
- Flores-Muñoz, F., Gutiérrez-Barroso, J., & Báez-García, A. (2019). Predictability and self-similarity in demand maturity of tourist destinations: The case of Tenerife. *Cuadernos de Economía*, 42, 59–69. <https://doi.org/10.32826/cude.v42i118.16>

- García, Ó. (2017). Forecasting tourism arrivals with an online search engine data: A study of the Balearic Islands. *PASOS. Revista de Turismo y Patrimonio Cultural*, 15(4), 943–958. Retrieved from www.pasosonline.org
- INEI. (2018). Instituto Nacional de Estadística e Informática - Pobreza por departamentos del Perú. Retrieved February 4, 2019, from <https://www.inei.gob.pe/estadisticas/indice-tematico/living-conditions-and-poverty/>
- Jarque, C., & Bera, A. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6(4), 255–259. [https://doi.org/10.1016/0165-1765\(81\)90035-5](https://doi.org/10.1016/0165-1765(81)90035-5)
- Jiménez, J., Sánchez, R., & Gázquez, J. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: una aplicación al sector turístico. *Revista Europea de Dirección y Economía de La Empresa*, 15(3), 185–198.
- Kulendran, N., & Wong, K. (2005). Modeling seasonality in tourism forecasting. *Journal of Travel Research*, 44(2), 163–170. <https://doi.org/10.1177/0047287505276605>
- Kwiatkowski, D., Phillips, P., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of Econometrics*, 54(1–3), 159–178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Laurente, L., & Machaca, R. (2020). Modeling and forecasting international tourism demand in Puno-Peru. *Revista Brasileira de Pesquisa Em Turismo*, 14(1), 34–55. <https://doi.org/10.7784/rbtur.v14i1.1606>
- Laurente, L., & Poma, R. (2016). *Introducción a la teoría de las probabilidades* (Primera Ed). Puno, Perú.
- Lee, C. K., Song, H. J., & Mjelde, J. W. (2008). The forecasting of International Expo tourism using quantitative and qualitative techniques. *Tourism Management*, 29(6), 1084–1098. <https://doi.org/10.1016/j.tourman.2008.02.007>
- Lewis, C. D. (1982). Industrial and business forecasting methods. *London: Butterworths*. Retrieved from <http://interstat.statjournals.net/YEAR/2008/articles/0810005.pdf>

- Ljung, G., & Box, G. (1978). Biometrika Trust On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297–303. <https://doi.org/10.1093/biomet/65.2.297>
- Mackinnon, J. (1996). Numerical Distribution Functions for Unit Root and Cointegration Tests. *Journal of Applied Econometrics*, 11(6), 601–618. [https://doi.org/10.1002/\(SICI\)1099-1255\(199611\)11:6<601::AID-JAE417>3.0.CO;2-T](https://doi.org/10.1002/(SICI)1099-1255(199611)11:6<601::AID-JAE417>3.0.CO;2-T)
- Makoni, T., & Chikobvu, D. (2018). Modelling and Forecasting Zimbabwe's Tourist Arrivals Using Time Series Method: A Case Study of Victoria Falls Rainforest. *Southern African Business Review*, 22, 1–22. <https://doi.org/10.25159/1998-8125/3791>
- Mishra, P. K., Rout, H., & Pradhan, B. (2018). Seasonality in Tourism and Forecasting Foreign Tourist Arrivals in India. *Iranian Journal of Management Studies*, 11(4), 629–658. <https://doi.org/10.22059/IJMS.2018.239718.672776>
- Msofe, Z. A., & Mbago, M. C. (2019). Forecasting international tourist arrivals in Zanzibar using Box–Jenkins ARIMA model. *General Letters in Mathematics*, 7(2), 100–107. <https://doi.org/10.31559/glm2019.7.2.6>
- OMS. (2020). Enfermedad por coronavirus (COVID-19) - Organización Mundial de la Salud. Retrieved June 28, 2020, from <https://www.who.int/es/emergencies/diseases/novel-coronavirus-2019/advice-for-public/q-a-coronaviruses>
- OPS. (2020). La OMS caracteriza a COVID-19 como una pandemia-Organización Panamericana de la Salud. Retrieved June 28, 2020, from <https://www.paho.org/es/noticias/11-3-2020-oms-caracteriza-covid-19-como-pandemia>
- Peiris, H. (2016). A Seasonal ARIMA Model of Tourism Forecasting: The Case of Sri Lanka. *Journal of Tourism, Hospitality and Sports*, 22, 98–109. Retrieved from <https://www.iiste.org/Journals/index.php/JTHS/article/view/33831>
- Pérez-Rodríguez, J., & Santana-Gallego, M. (2020). Modelling tourism receipts and associated risks, using long-range dependence models. *Tourism Economics*, 26(1), 70–96. <https://doi.org/10.1177/1354816619828170>

- PERU. (2020). COVID-19: El sector turismo no está solo-Gobierno del Perú. Retrieved June 26, 2020, from <https://www.gob.pe/institucion/mincetur/noticias/109877-covid-19-el-sector-turismo-no-esta-solo>
- Petrevska, B. (2017). Predicting tourism demand by ARIMA models. *Economic Research-Ekonomika Istraživanja*, 30(1), 939–950. <https://doi.org/10.1080/1331677X.2017.1314822>
- Phillips, P. C., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335–346. <https://doi.org/10.1093/biomet/75.2.335>
- Ray, B. K. (1993). Modeling Long Memory Processes for Optimal Long Range Prediction. *Journal of Time Series Analysis*, 14(5), 511–525. <https://doi.org/10.1111/j.1467-9892.1993.tb00161.x>
- RPP. (2020). Coronavirus y el golpe al turismo: ¿Cómo impacta la crisis en el empleo?-RPP Noticias. Retrieved June 26, 2020, from <https://rpp.pe/peru/actualidad/coronavirus-y-el-golpe-al-turismo-como-impacta-la-tesis-en-el-empleo-noticia-1257442>
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, 6(2), 461–464. <https://doi.org/10.1214/aos/1176344136>
- Uwilingiyimana, C., Munga’Tu, J., & Harerimana, J. D. D. (2016). Forecasting Inflation in Kenya Using Arima - Garch Models. *International Journal of Management and Commerce Innovations*, 3(2), 15–27.
- Ying-Fang, H., Thanh-Lam, N., & Ming-Hung, S. (2014). Forecasting inbound tourism demand in thailand with grey model. *Recent Researches in Applied Economics and Management*, 13(1), 95–104.