



**20  
17**

**METODOLOGÍA DE  
PROYECCIONES A CORTO  
PLAZO DE LLEGADA DE  
TURISTAS PARA EL AÑO 2017**

**Box and Jenkins**

# METODOLOGÍA DE PROYECCIONES A CORTO PLAZO DE LLEGADA DE TURISTAS PARA EL AÑO 2017

## Box and Jenkins

**FOTO DE PORTADA:**

**Nombre:** Laguna Santa Rosa

**Autor:** SERNATUR

**Región:** Región de Atacama

**Provincia:** Copiapó

**Comuna:** Copiapó

**ELABORADO POR:**

Departamento de Estadísticas

SERVICIO NACIONAL DE TURISMO

División de Estudios

SUBSECRETARÍA DE TURISMO

Publicado en junio 2017

## Indice

<b>Indice</b> .....	<b>3</b>
<b>METODOLOGÍA ANÁLISIS DE PROYECCIONES 2017</b> .....	<b>5</b>
Métodos de series temporales.....	6
Análisis de las series temporales.....	6
Indicadores de sensibilidad, autocorrelación y serie diferenciada.....	7
Criterio de Akaike .....	8
Pruebas de normalidad .....	8
Autocorrelación simple, parcial y test de L Jung box.....	8
<b>MODELOS ESTADÍSTICOS DE PROYECCIONES POR VARIABLES</b> .....	<b>10</b>
Modelos de Box-Jenkins.....	10
Estructura modelo SARIMA.....	10
Modelos SARIMA (p,d,q)(P,D,Q) <sub>s</sub> .....	11
Proceso de cálculo de parámetros .....	11
Etapa construcción del modelo Box Jenkins .....	12
<b>ANÁLISIS MERCADO TOTAL DE LLEGADAS DE TURISTAS ARGENTINOS</b> .....	<b>13</b>
Prueba de co-integración mercado llegadas mundiales y arribos de turistas argentinos. .....	13
<b>ANÁLISIS DE LA LLEGADA DE TURISTAS ARGENTINOS DURANTE EL 2008 AL 2016. ...</b>	<b>17</b>
<b>Turistas argentinos</b> .....	<b>17</b>
Análisis residual para determinar autocorrelación serial .....	20
Análisis residual para determinar normalidad de Gauss .....	21
Resultados del modelo aplicado para la llegada de turistas argentinos.....	22
<b>Turistas a nivel mundial</b> .....	<b>23</b>
Análisis mercado total de llegadas de turistas a nivel mundial .....	23
Análisis residual para determinar autocorrelación serial .....	27
Análisis residual para determinar normalidad de Gauss .....	28
Resultados del modelo aplicado para la llegada de turistas a nivel mundial .....	29

<b>Turistas estadounidenses .....</b>	<b>30</b>
Análisis mercado total de llegadas de turistas estadounidenses.....	30
Análisis residual para determinar autocorrelación serial .....	34
Análisis residual para determinar normalidad de Gauss .....	35
Resultados del modelo aplicado para la llegada de turistas estadounidenses.....	36
<b>Turistas europeos .....</b>	<b>37</b>
Análisis mercado total de llegadas de turistas europeos.....	37
Análisis residual para determinar autocorrelación serial .....	40
Análisis residual para determinar normalidad de Gauss .....	41
<b>Turistas brasileños .....</b>	<b>43</b>
Análisis mercado total de llegadas de turistas de Brasil. ....	43
Análisis residual para determinar autocorrelación serial .....	46
Análisis residual para determinar normalidad de Gauss .....	47
Resultados del modelo aplicado para la llegada de turistas brasileños.....	48
<b>Bibliografía .....</b>	<b>50</b>
<b>Anexos .....</b>	<b>51</b>

# 01 | CAPÍTULO 1

## METODOLOGÍA ANÁLISIS DE PROYECCIONES 2017

Para alcanzar los objetivos de esta primera etapa que consiste en pronosticar el año 2017, considerando los datos a partir de agosto del 2016. Se consideraron los siguientes países como objeto de estudio para su posterior proyección. Total de llegadas de argentinos, brasileiros, europeos y estado unidenses, a su vez se trabajó el total de llegadas de Turistas a nivel mundial. Las variables sometidas tienen un carácter cuantitativo discreto.

Los periodos medidos para este análisis corresponden a datos mensuales muestreados desde enero a diciembre concernientes a los años 2012 y hasta agosto del 2016. La fuente de información es Elaborada por la Subsecretaría de Turismo y Sernatur en base a información proporcionada por la Jefatura Nacional de Extranjería y Policía Internacional de Chile; y Carabineros de Chile (OS3).

Para conocer una visión diagnóstico de las variables target, como método robusto de análisis se procedió el uso de herramientas de estadística descriptiva para valorar promedios y variabilidades de las variables indexadas en el tiempo. No obstante, a modo inferencial utilizamos análisis de varianzas para valorar si existieron diferencias significativas al 5% en cuanto al comportamiento de las medias anuales y de relativa importancia la variabilidad en cada año de las variables medidas, es decir su variabilidad anual y cuan volátil resultó ser en cada periodo.

Se aplicó a las variables una transformación logarítmica para suavizar la volatilidad de éstas en el tiempo. Aquello se sustentó en la alta variabilidad que mostraron las variables y los resultados de las estadísticas descriptivas e inferenciales. Como métodos gráficos se usaron graficas de perfiles de medias para sus respectivos años y Box Plots, los cuales permiten dar una visión generalizada de las variables según periodo.

Una vez analizadas las variables de manera descriptiva e inferencial, se procedió a usar metodología de series temporales las cuales permiten dar las herramientas para realizar las proyecciones hasta el año 2017. Aquella metodología será detallada según sus aspectos fundamentales y definitorios.

Para llevar a cabo la metodología de proyecciones, se usó el software R Proyect el cual es de libre acceso y no requiere licencia, no obstante para realizar los análisis descriptivos e inferenciales utilizamos el programa computacional SPSS 19.

## Métodos de series temporales

Una serie de tiempo es una secuencia ordenada de valores de una variable en intervalos de tiempo periódicos y consecutivos. Los métodos de análisis de series de tiempo consideran el hecho que los datos tomados en diversos periodos de tiempo pueden tener algunas características de tendencia, variaciones cíclicas, estacionalidad y una componente de error (variaciones de causalidad) que se debe tomar en cuenta (Galbiati J, 2000). A continuación se describen los componentes de una serie temporal.

La tendencia se define como el comportamiento predominante de la serie. Esta puede ser definida vagamente como el cambio de la media a lo largo de un extenso periodo de tiempo.

El término variación cíclica se suele referir a ciclos grandes, cuyo período no es atribuible a alguna causa. Por ejemplo, fenómenos climáticos, que tienen ciclos que duran varios años.

La variación estacional representa un movimiento periódico de la serie de tiempo. La duración del período puede ser un año, un trimestre, un mes, un día, etc.

Los movimientos irregulares (al azar) o error, representan todos los tipos de movimientos de una serie de tiempo que no sea tendencia, variaciones estacionales y fluctuaciones cíclicas.

## Análisis de las series temporales

Para realizar los pronósticos de las variables estudiadas, se procederá a regirse por los pasos establecidos dentro del ámbito de las series temporales, como primera etapa se deben estudiar los componentes que subyacen a las variables indexadas en el tiempo. A continuación se describen los pasos básicos que se realizaron para proponer modelos estadísticos que nos permitirán realizar las proyecciones para el año 2017. Cabe destacar que para la propuesta de modelos estadísticos de predicción, la serie temporal debe ser estacionaria es decir que no tenga tendencia y su variabilidad sea constante durante todo el periodo considerado, a su vez se describen los indicadores que utilizaremos como medidas de bondad de ajuste, las que nos permitirán detectar cual es el mejor modelo a usar para predecir, se debe acentuar que existe también un juicio de experto respecto a la sensibilidad del modelo y/o modelos que se puso a prueba. A continuación se exponen los pasos a seguir para la propuesta de modelos de proyección, no obstante los conceptos tales como función de correlación y diferenciación se explicarán durante el avance de la metodología.

El primer paso consistió en graficar las series de tiempo (la variable objeto de estudio) con el fin de detectar sus componentes tales como tendencias, componentes estacionales, variaciones cíclicas y el error aleatorio que presentará.

Dado que las series presentaban cierto grado de volatilidades, se aplicó una transformación logarítmica a los datos bajo la metodología de Box y Cox.

Debido a que las series poseían tendencia clara, estas fueron diferenciada con el fin de ser estacionarias

Obteniendo las series estacionarias, estas se graficaron bajo su función de autocorrelación simple y parcial, con el fin de detectar un posible modelo tentativo para realizar proyecciones.

Una vez considerado un modelo tentativo para predecir, este fue puesto a prueba bajo ciertos criterios tales como menores indicadores de sensibilidad y comparaciones entre datos reales con los pronosticados del modelo propiamente tal.

Por último se revalidó el modelo de acuerdo a un análisis de sensibilidad de los datos ajustados por este y se verifican que los errores estén no correlacionados.

### Indicadores de sensibilidad, autocorrelación y serie diferenciada.

Estos indicadores sirven para comparar la efectividad de diferentes modelos utilizados. Siempre se busca el valor menor en los indicadores MAPE, MAD y MSD ya que representa un mejor ajuste del modelo (Uriel, 1993).

*MAPE*: Porcentaje promedio absoluto de error, mide la exactitud de los valores estimados de la serie de tiempo. La exactitud se expresa en valor absoluto como un porcentaje con  $y_t$  igual al valor observado,  $\hat{y}_t$  es el valor estimado y  $n$  el número de observaciones.

$$MAPE = \sum_{i=1}^n \left| \frac{(y_t - \hat{y}_t)}{y_t} \right| * \frac{1}{n} \quad y_t \neq 0$$

*MAD*: Desviación media absoluta, mide la exactitud de los valores estimados de la serie de tiempo. Expresa la exactitud en las mismas unidades de los datos.

$$MAD = \sum_{i=1}^n |(y_t - \hat{y}_t)| * \frac{1}{n} \quad y_t \neq 0$$

*MSD*: Desviación cuadrática media, es más sensible a errores anormales de pronóstico que el MAD.

$$MSD = \sum_{i=1}^n (y_t - \hat{y}_t)^2 * \frac{1}{n} \quad y_t \neq 0$$

Diferenciar una serie consiste en calcular diferencias entre los valores de los datos de la serie de tiempo, cuya utilidad sirve para identificar patrones de tendencia y estacionalidad.

$$diff = y_t - y_{t-1} \quad \text{con } t = 1, 2 \dots n \text{ periodos de tiempo}$$

## Criterio de Akaike

El criterio de información de Akaike (AIC) es una medida de la calidad relativa de un modelo estadístico, para un conjunto dado de datos. Como tal, el AIC proporciona un medio para la selección del modelo.

AIC maneja un trade-off entre la bondad de ajuste del modelo y la complejidad del modelo. Se basa en la entropía de información: se ofrece una estimación relativa de la información perdida cuando se utiliza un modelo determinado para representar el proceso que genera los datos.

AIC no proporciona una prueba de un modelo en el sentido de probar una hipótesis nula, es decir AIC puede decir nada acerca de la calidad del modelo en un sentido absoluto. Si todos los modelos candidatos encajan mal, AIC no dará ningún aviso de ello. En el caso general, la AIC es  $AIC=2k-2\ln(L)$  donde  $k$  es el número de parámetros en el modelo estadístico, y  $L$  es el máximo valor de la función de verosimilitud para el modelo estimado.

Dado un conjunto de modelos candidatos para los datos, el modelo preferido es el que tiene el valor mínimo en el AIC. Por lo tanto AIC no sólo recompensa la bondad de ajuste, sino también incluye una penalidad, que es una función creciente del número de parámetros estimados. Esta penalización desalienta el sobreajuste (aumentando el número de parámetros libres en el modelo mejora la bondad del ajuste, sin importar el número de parámetros libres en el proceso de generación de datos).

## Pruebas de normalidad

Se aplicó el test de Shapiro Wilk para determinar si los datos se ajustan a una distribución normal, para ello se postuló una hipótesis nula la cual indica que la variable aleatoria no tiene una distribución normal versus una alternativa que indica que la variable aleatoria si tiene una distribución normal. Para determinar la existencia de diferencias significativas se usó un nivel de significancia del 5%. Por ultimo como apoyo gráfico se modeló la variable mediante gráficos de cuantiles de normalidad, la cual nos permite comparar la distribución empírica de un conjunto de datos con la distribución Normal, para determinar así posibles desviaciones de los puntos respecto a la línea diagonal del gráfico. Mientras mayores sean los puntos respecto de la diagonal mayor será la lejanía a que los datos se ajusten a la distribución normal.

## Autocorrelación simple, parcial y test de Ljung box

**La autocorrelación simple** es la correlación entre observaciones de una serie de tiempo separadas por  $K$  unidades de tiempo, su gráfica se denomina función de autocorrelación (ACF). Una gráfica de autocorrelación, permite identificar un posible modelo de proyección de acuerdo a la estructura de esta.

**La autocorrelación parcial** es la correlación entre conjuntos de pares ordenados de una serie de tiempo, mide la fuerza de la relación con otros términos tomados en cuenta. Su gráfica nos permite encontrar el orden del modelo estadístico a aplicar, el orden hace referencia al número de parámetros del modelo.



Estructura matemática de la función de autocorrelación genérica.

$$\rho_t = \frac{\text{cov}(y_t, y_{t-1})}{\sqrt{\text{var}(y_t) * \text{var}(y_{t-1})}} \quad \text{donde } \text{var}(y_t) = \text{var}(y_{t-1}) \text{ caso estacionario}$$

Para determinar que no exista autocorrelación en los errores del modelo se aplicó el test de Ljung-Box, en el cual el criterio que se definió fue detectar la posible autocorrelación a un nivel de significancia del 5% valorando el valor p del test. Cabe destacar que si existe el problema de autocorrelación de los errores, los parámetros del modelo de predicción serán insuficientes y por ende habrá exceso de variabilidad en ellos mismos con un impacto de inconsistencia en los pronósticos entregados.

$H_0$ : No existe correlación en los errores vs  $H_1$ : Existe correlación en los errores

El test se representa por:  $Q = n(n+2) * \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k}$   $n$  es tamaño de muestra

$\hat{\rho}_k^2$  Es la autocorrelación de la muestra en el retraso  $k$  y  $h$  es el número de retardos que se están probando

Por nivel de significación  $\alpha$ , la región crítica para el rechazo de la hipótesis de aleatoriedad es  $Q > X_{(1-\alpha, h)}^2 \sim \text{Chi cuadrada con rechazo de } H_0 \text{ si el valor } p \text{ es menor al } 5\%$

## 02 | CAPÍTULO 2

### MODELOS ESTADÍSTICOS DE PROYECCIONES POR VARIABLES

#### Modelos de Box-Jenkins

Una característica esencial de las series temporales es la dependencia que existe entre las observaciones de la variable. La metodología de Box-Jenkins modela esta dependencia utilizando la teoría probabilística suministrada por los procesos estocásticos estacionarios y la metodología estadística suministrada por la teoría de la estimación y contraste de hipótesis. Un proceso estocástico es una colección de variables indexadas por el tiempo  $\{Y(t)\}_{t \in T}$

Se aplicó la metodología de Box-Jenkins debido a que en las series utilizadas en este estudio, poseían además de variaciones aleatorias y cíclicas, tendencia y componentes estacionales, que hacen que los procesos estacionarios anteriormente citados no sean suficientes para su modelado y posterior aplicación. Por esta razón se introducen los modelos integrados, mediante los cuales retiramos la componente tendencial y estacional.

Para el análisis de nuestras series aplicamos la metodología de modelaje ARIMA considerando componentes estacionales, es decir modelos definidos como SARIMA, debido a que al analizar las componentes de las series, se observaron estacionalidades claras y tendencias a lo largo del periodo. Aquello se detectó mediante las gráficas de la serie, procedimientos de descomposición estacional, gráficos de periodograma y principalmente las gráficas de las funciones de autocorrelación parcial y simple, que valoran la estructura interna de la serie analizada.

El método SARIMA, el cual se detallará su estructura matemática posteriormente, en estricto rigor modela la serie eliminando la tendencia y su componente estacional, es decir, transforma la serie en estacionaria y con ello se logra definir un modelo de proyección más confiable (Box,1976).

#### Estructura modelo SARIMA

A continuación se define la estructura estadística del modelo SARIMA junto a sus componentes y se detallan breves explicaciones de ellas.

## Modelos SARIMA (p,d,q)(P,D,Q)<sub>s</sub>

La expresión genérica del modelo es la siguiente:

$$\phi(B)\Phi(B^s)(W_t - \mu) = \theta(B)\Theta(B^s)Z_t$$

$$W_t = (1 - B)^d (1 - B^s)^D Y_t = \Delta^d \Delta_s^D (Y_t)$$

Los operadores introducidos en las fórmulas son:

$B^s$ : operador de retardo estacional definido  $B^s(Y_t) = Y_{t-s}$

$\Delta = (1-B)$  operador diferencia regular

$\Delta_s = (1-B^s)$  operador diferencia estacional

Los operadores de diferencias de la parte regular (p,d,q) y diferencia estacional (P,D,Q)<sub>s</sub>, en general quitan tendencias y componentes estacionales de la serie respectivamente.

$W_t$  es la serie desestacionalizada y sin tendencia, es decir, es estacionaria.

$Y_t$ : serie observada

B: Operador de retardos

$\phi(B)$ : Polinomio autorregresivo de orden p, correspondiente a la parte regular de la serie

$\theta(B)$ : Polinomio de medias móviles de orden q, correspondiente a la parte regular de la serie

$\Phi(B^s)$ : Polinomio autorregresivo de orden P, correspondiente a la parte estacional de la serie

$\Theta(B^s)$ : Polinomio de medias móviles de orden Q, correspondiente a la parte estacional de la serie

$\mu$  : La media de la serie estacionaria

$Z_t$ : Perturbación del modelo u/o error aleatorio con distribución Gauss Markov

D,d: Número de veces que se han aplicado los operadores diferencia estacional y diferencia regular a la serie original para convertirla en estacionaria.

Las raíces de  $\phi(B)$ ,  $\Phi(B^s)$ ,  $\theta(B)$  y de  $\Theta(B^s)$  fuera del círculo unidad

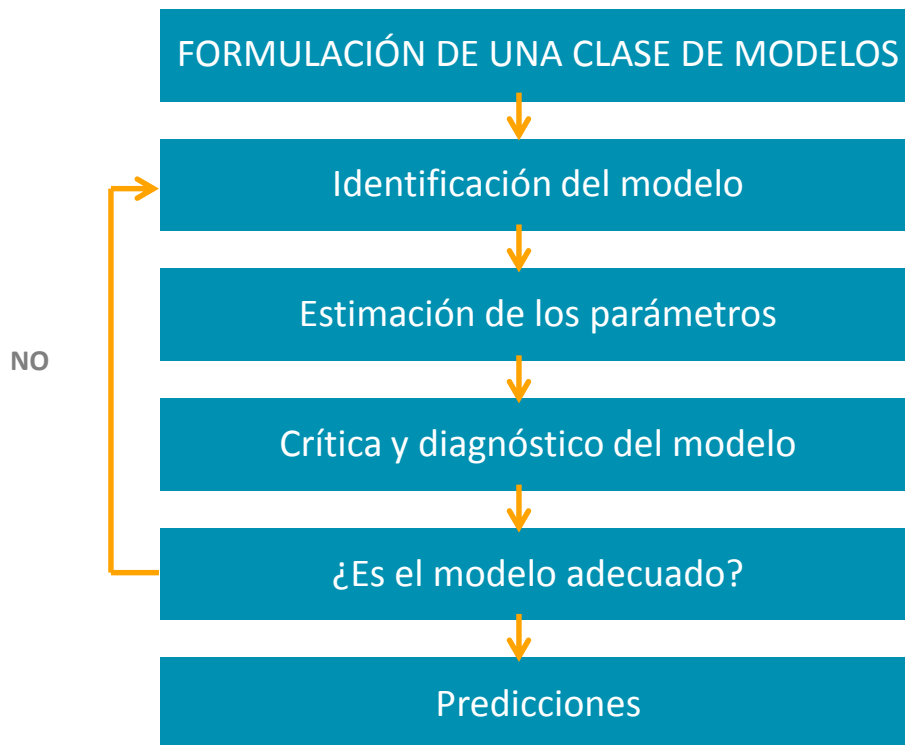
$S=12$  para nuestro caso dado que las series son mensuales.

## Proceso de cálculo de parámetros

Como se mencionó anteriormente el software utilizado para realizar las estimaciones del modelo, es decir calcular los parámetros ya detallados, cuyo propósito consiste en obtener las proyecciones, fueron realizadas en el programa R Project mediante sub rutinas de programación y SPSS para ciertos aspectos. Las cuales permiten estimar el valor de cada parámetro mediante el método de máxima verosimilitud, mejorando la precisión que ofrece la estimación tradicional. La evaluación por el método de máxima verosimilitud procura encontrar los valores más probables de los parámetros de la distribución para un conjunto de datos. Maximizando el valor de lo que se conoce como la "función de verosimilitud".

La estrategia para la construcción del modelo se basa en un ciclo iterativo, en el que la elección de la estructura del modelo se basa en sus propios datos. Las etapas del ciclo iterativo son:

### Etapa construcción del modelo Box Jenkins



# 03 | CAPÍTULO 3

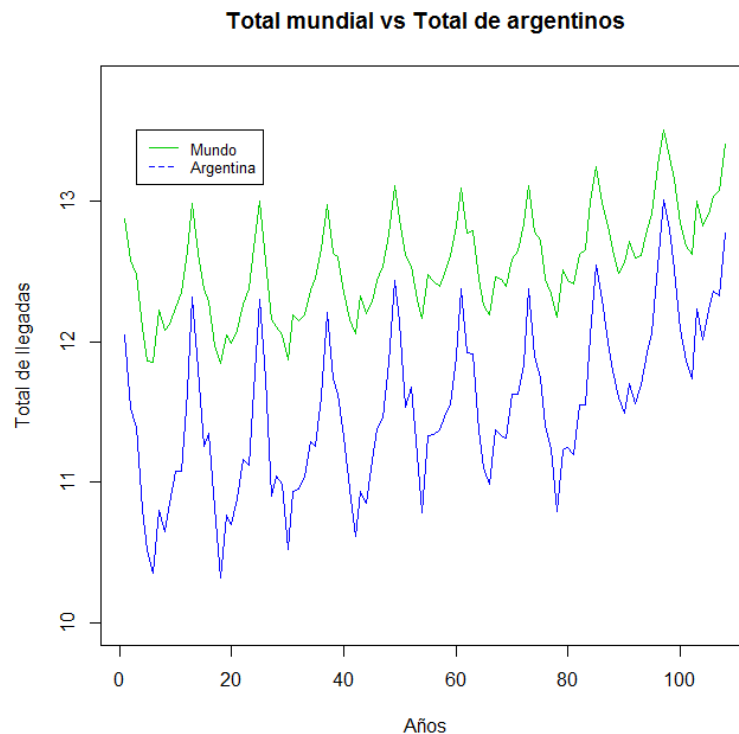
## ANÁLISIS MERCADO TOTAL DE LLEGADAS DE TURISTAS ARGENTINOS

### Prueba de co-integración mercado llegadas mundiales y arribos de turistas argentinos.

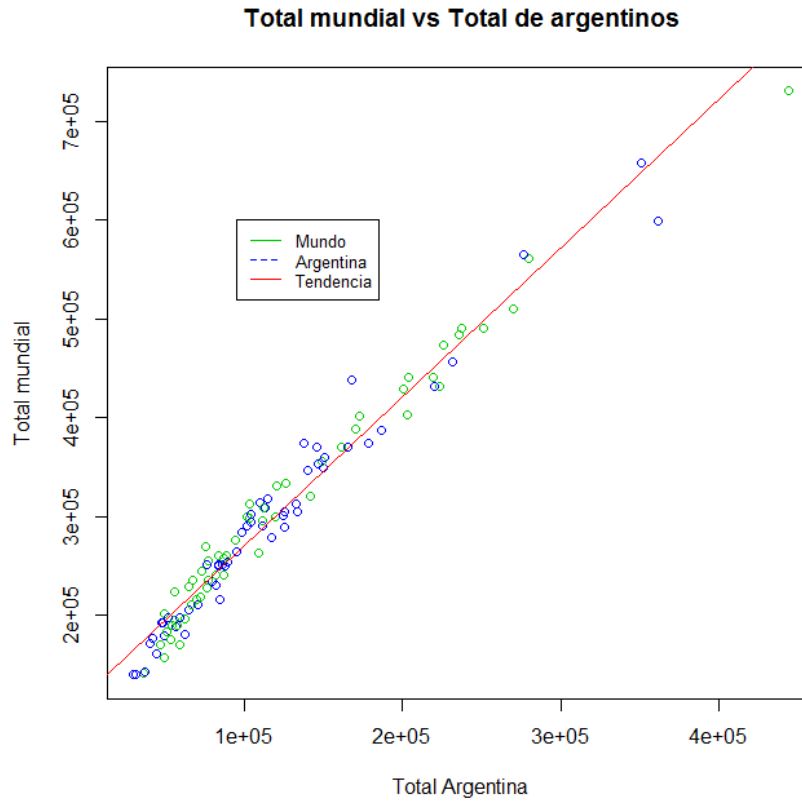
Para determinar si las variables están Co-integradas o no, Es decir, se analiza si existe una relación de largo plazo a través de una regresión de las variables en niveles y se analiza si la variable residual es estacionaria.

Si las variables están Co-integradas el modelo se establece en términos de las series en niveles y se incluye un mecanismo de corrección de error. Si las variables no están Co-integradas, el modelo se estimaría en términos de las transformaciones estacionarias.

**GRAFICO 1: COMPARACIÓN DE LAS SERIES DE LLEGADAS DE TURISTAS A NIVEL MUNDIAL VERSUS LA LLEGADA DE TURISTAS ARGENTINOS.**




**GRAFICO 2: COMPARACIÓN DE LAS SERIES DE LLEGADAS DE TURISTAS A NIVEL MUNDIAL VERSUS LA LLEGADA DE TURISTAS ARGENTINOS SEGÚN GRADO DE ASOCIACIÓN LINEAL.**




Se aprecia una tendencia lineal entre el comportamiento de ambas series temporales de total de llegadas, para determinar si existe una relación de equilibrio a largo plazo (Co-integración) se procedió a realizar el análisis de Co-integración. Para ello se analizaron los residuales de la regresión entre ambas series temporales.

**GRAFICO 3: DETERMINACIÓN DE LA ESTRUCTURA ESTACIONARIA PARA LOS RESIDUOS DEL MODELO AJUSTADO.**



Al aplicar el test Ndiffs, el cual utiliza una prueba de raíz unitaria para determinar el número de diferencias requeridas para que la serie temporal se haga estacionaria, a los residuos del modelo, se logró determinar que existe una raíz unitaria en los residuos estimados. Por ende se determina que los residuos no son estacionarios según este test basado en los métodos kpss, Dickey-Fuller y Phillips-Perron. Bajo estas circunstancias se determina que las series no están Co-integradas. Por ende no se requiere aplicar un modelo de Vector de Corrección de Errores (VEC). En consecuencia se analizan las series para estos mercados y los otros de manera independiente.

GRAFICO 4: TENDENCIA DE LOS RESIDUOS DEL MODELO ANTERIOR.



Se aprecia que existe una tendencia respecto a los residuos del modelo, cuya pendiente resultó ser significativa al 5%, lo cual reafirma la posición de que existe una raíz unitaria, por ende no hay estacionariedad. Concluyendo que no se evidencia una relación de equilibrio en ambas series de llegadas de Turistas.



# 04 | CAPÍTULO 4

## ANÁLISIS DE LA LLEGADA DE TURISTAS ARGENTINOS DURANTE EL 2008 AL 2016.

### Turistas argentinos

GRAFICO 5: TENDENCIA DE LA LLEGADA DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.



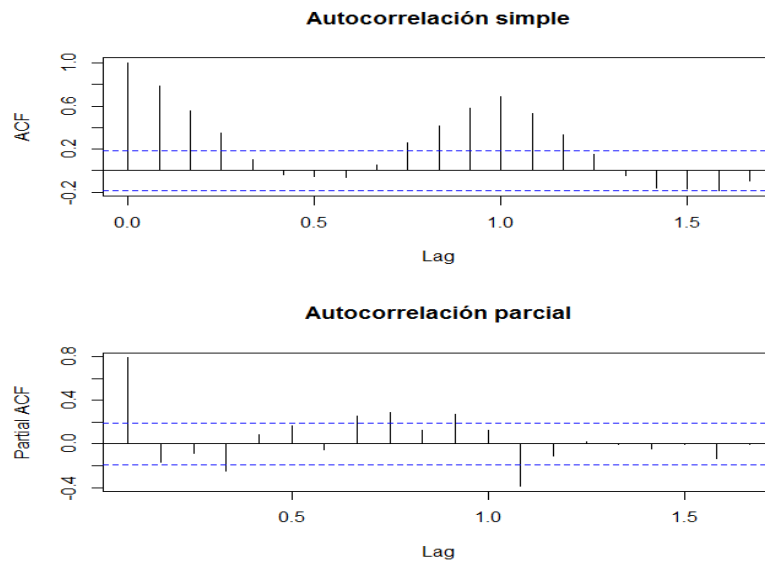



GRAFICO 6: DESCOMPOSICIÓN DE LA SERIE DE LLEGADAS DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.





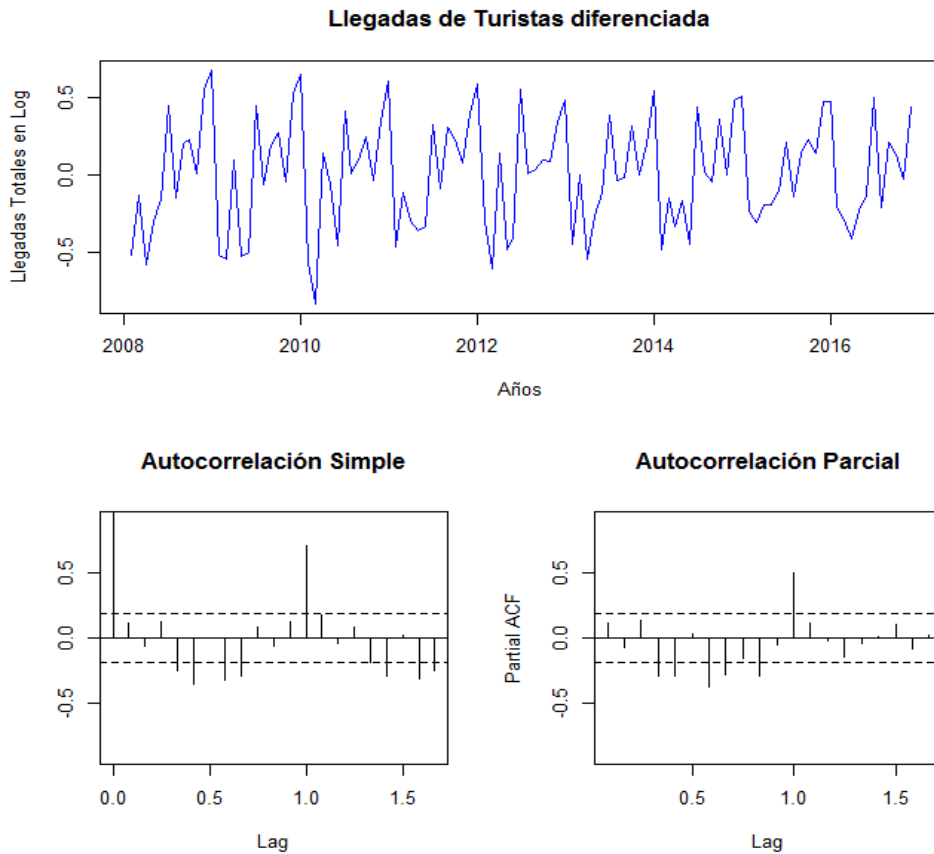
Se aprecian claras tendencias estacionales y de crecimiento durante los años de evolución histórica de la serie según el gráfico de lo observado y el comportamiento de su función de autocorrelación simple (ACF), a su vez, visualmente se ve un comportamiento aleatorio de las variaciones influyente por factores externos. Bajo estas circunstancias se procede a diferenciar el proceso para lograr que sea estacionario respecto a su tendencia y componente cíclica.

**GRAFICO 7: DIFERENCIACIÓN DE LA SERIE DE LLEGADAS DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.**



Se procedió a diferenciar la serie de tiempo para la parte regular y estacional, fundamentándose en el procedimiento ndiffs explicado anteriormente, el cual indicó una diferencia para la tendencia y la componente estacional. Respecto a ello se procedió a estimar la función de correlación parcial y simple para determinar el orden y el número de parámetros del modelo con mejor ajuste a los datos.

**GRAFICO 8: AUTOCORRELACIÓN SIMPLE Y PARCIAL DE LA SERIE DE LLEGADAS DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.**

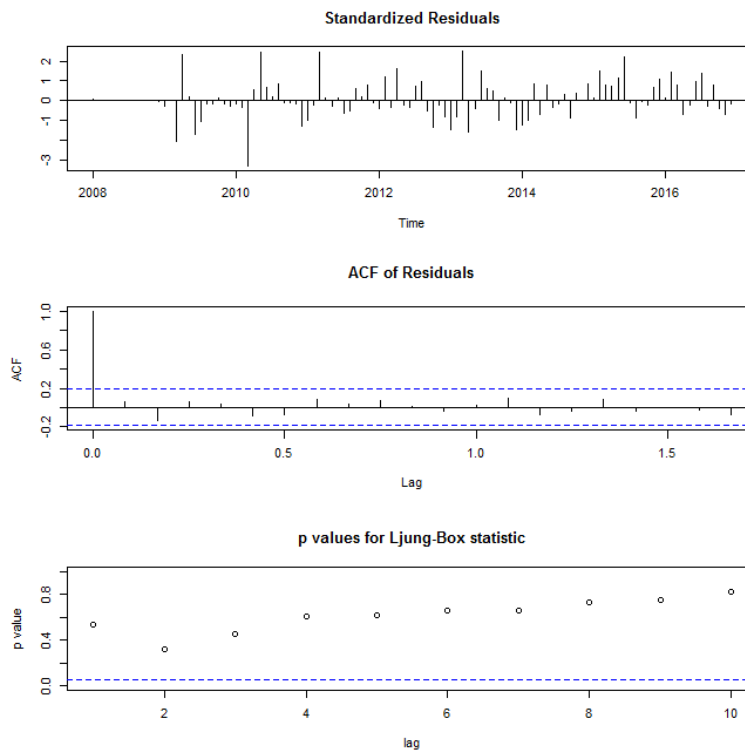


Se aprecia que en ambas funciones existe un rezago significativo para el rezago doceavo, lo cual evidencia la estacionalidad del comportamiento de esta serie temporal, además en la función de autocorrelación simple no se evidencia un comportamiento de caída exponencial en los primeros rezagos, lo cual da indicios de posibles comportamientos de medias móviles y no autoregresivos para la parte regular, pero si podríamos indicar que en la parte estacional hay al menos una componente regular. De acuerdo a lo anterior se procede a estimar un modelo que permita representar el comportamiento estocástico de la serie analizada. Aquel modelo debe medir estacionalidad y por ende se aplicó la metodología ARIMA estacional a doce meses. Para esto se aplicó el modelo SARIMA (0, 1,1) (1, 1,1)<sub>12</sub> en consecuencia de que resultó el con mejor poder predictivo en contraste con la realidad.

### Análisis residual para determinar autocorrelación serial

Una vez determinado lo anterior, se decide aplicar el modelo SARIMA (0, 1,1) (1, 1,1)<sub>12</sub> junto con su evaluación de los residuales con el fin de determinar existencias de autocorrelación para estos.

**GRAFICO 9: AUTOCORRELACIÓN Y DIAGNÓSTICO DE LOS RESIDUOS DE LA SERIE DE LLEGADAS DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.**




Gráficamente no se detecta el problema de la autocorrelación en los residuos de este modelo, sin embargo se procede a validar el supuesto mediante el test de autocorrelación de Ljung-Box el cual a un 5% de significancia determinó que no existe autocorrelación residual para el modelo.

### Análisis residual para determinar normalidad de Gauss

Se procede a determinar la existencia de normalidad en los residuos, mediante gráficos de probabilidad normal y el test Shapiro Wilk, obteniéndose los siguientes resultados.


**GRAFICO 10: DETERMINACIÓN DE NORMALIDAD MEDIANTE CUANTILES PARA LLEGADA DE TURISTAS ARGENTINOS DURANTE 2008 AL 2016.**



Gráficamente se aprecia que hay desviaciones en las colas de la distribución, por ende no se cumpliría el supuesto de la normalidad, no obstante se aplicó el test de Shapiro Wilk a un nivel de significancia del 5% el cual determinó que no existe normalidad en los residuales.

## Resultados del modelo aplicado para la llegada de turistas argentinos

A continuación se presentan los resultados del modelo ajustado para la serie analizada, además se valora el gráfico de la serie real en conjunto a la serie estimada.



Información del modelo:

**TABLA 1: COEFICIENTES DEL MODELO APLICADO**

SARIMA(0,1,1)(1,1,1) <sub>12</sub>	MA(1)	SAR(1)	SMA(1)
<b>Parámetros</b>	-0.6114	-0.0996	-0.6956
<b>Desviaciones estándar</b>	0.0862	0.1763	0.1775

**TABLA 2: BONDADES DE AJUSTES DEL MODELO**

Errores de medición	MAPE (%)	MAD	MSD	Varianza
<b>Log</b>	0,8425	0,0973	0,1382	0,0217
<b>Anti log</b>	2,3221	1,1022	1,1482	1,0219

Se valoró el criterio de Akaike el cual es un estadístico basado en la teoría de información y las propiedades del método de máxima verosimilitud, para seleccionar el mejor modelo. Se determina un buen modelo el cual posee un menor valor de Akaike en comparación con otros. En nuestro caso el modelo entrega un Akaike de -76.23. El coeficiente de determinación del modelo resultó ser de 0,93.

Para determinar el poder predictivo del modelo, se determinó la predicción de noviembre del 2016 a febrero del 2017, obteniéndose los siguientes resultados.


Serie Argentina	nov-16	dic-16	ene-17	feb-17
<b>Dato proyectado</b>	250.356	375.626	638.068	450.152
<b>Dato real</b>	225.712	350.654	647.955	<b>464.664</b>
<b>Variación real/proyectado</b>	<b>10,92%</b>	<b>7,12%</b>	<b>-1,53%</b>	<b>-3,12%</b>

Se observa que las estimaciones de los meses de enero y febrero son bastante precisas según los totales reales, por otra parte, Al proyectar febrero usando los datos reales hasta el mes de enero del 2017, el error de pronóstico, el error de pronóstico corresponde a una subestimación de un 6%. (Febrero ajustado 436.634)

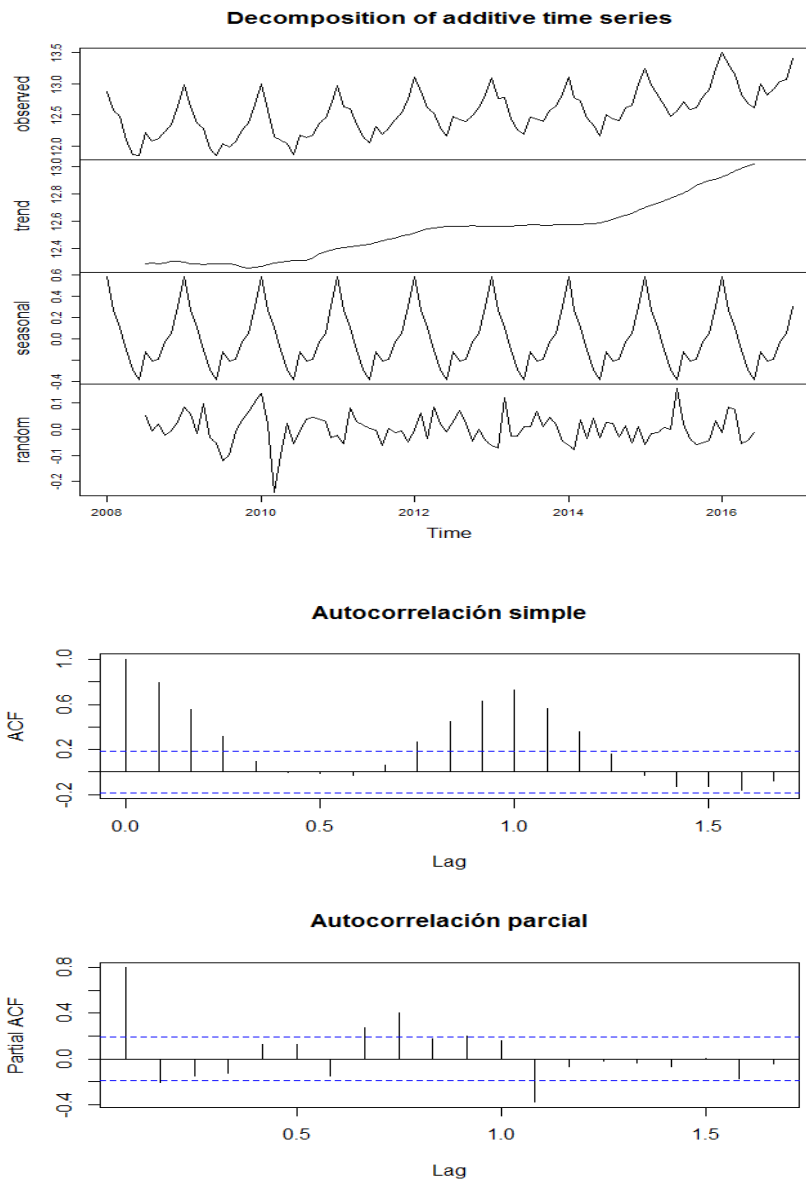
## Turistas a nivel mundial

### Análisis mercado total de llegadas de turistas a nivel mundial

**GRAFICO 11: TENDENCIA DE LA LLEGADA DE TURISTAS A NIVEL MUNDIAL DURANTE 2008 AL 2016.**




**GRAFICO 12: DESCOMPOSICIÓN DE LA SERIE DE LLEGADAS DE TURISTAS MUNDIALES DURANTE 2008 AL 2016**



Se aprecian claras tendencias estacionales y de crecimiento durante los años de evolución histórica de la serie según el grafico de lo observado y el comportamiento de su función de autocorrelación simple (ACF), a su vez, visualmente se ve un comportamiento estacional. Bajo estas circunstancias se procede a diferenciar el proceso para lograr que sea estacionario respecto a su tendencia y componente estacional.

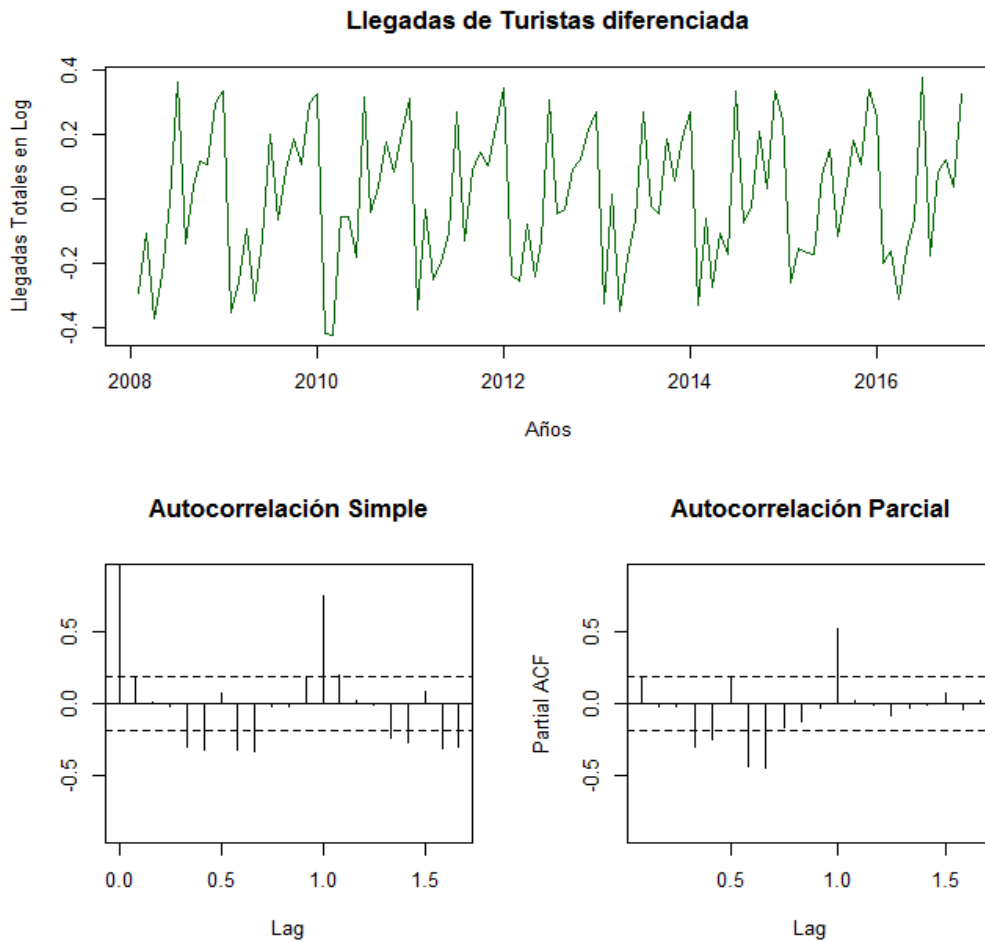


**GRAFICO 13: DIFERENCIACIÓN DE LA SERIE DE LLEGADAS DE TURISTAS MUNDIALES DURANTE 2008 AL 2016.**



Se procedió a diferenciar la serie de tiempo para la parte regular y estacional, fundamentándose en el procedimiento ndiffs explicado anteriormente, el cual indicó una diferencia para la parte regular. Respecto a ello se procedió a estimar la función de correlación parcial y simple para determinar el orden y el número de parámetros del modelo con mejor ajuste a los datos.

**GRAFICO 14: AUTOCORRELACIÓN SIMPLE Y PARCIAL DE LA SERIE DE LLEGADAS DE TURISTAS DURANTE 2008 AL 2016.**

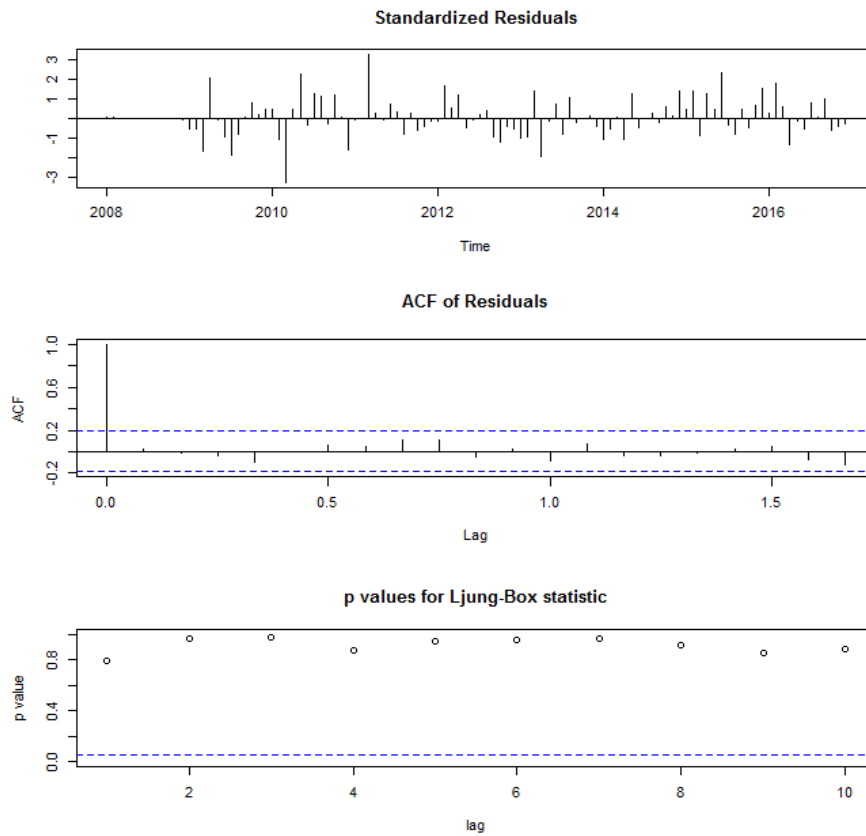


Se aprecia que en ambas funciones existe un rezago significativo para el rezago doceavo, lo cual evidencia la estacionalidad del comportamiento de esta serie temporal, además en la función de autocorrelación simple no se evidencia un comportamiento de caída exponencial en los primeros rezagos, lo cual da indicios de posibles comportamientos de medias móviles y no autoregresivos para la parte regular. Sin embargo al iterar modelos con las características anteriores, se obtuvieron proyecciones con bajo poder predictivo según las llegadas reales de Turistas. El modelo con mejor poder predictivo resultó ser SARIMA (2, 1,3) (1, 1,0)<sub>12</sub> estacional a 12 meses.

### Análisis residual para determinar autocorrelación serial

Una vez determinado lo anterior, se decide aplicar el modelo SARIMA (2, 1,3) (1, 1,0)<sub>12</sub> junto con su evaluación de los residuales con el fin de determinar existencias de autocorrelación para estos.

**GRAFICO 15: AUTOCORRELACIÓN Y DIAGNÓSTICO DE LOS RESIDUOS DE LA SERIE DE LLEGADAS DE TURISTAS MUNDIALES DURANTE 2008 AL 2016.**




Gráficamente no se detecta el problema de la autocorrelación en los residuos de este modelo, sin embargo se procede a validar el supuesto mediante el test de autocorrelación de Ljung-Box el cual a un 5% de significancia determinó que no existe autocorrelación residual para el modelo.

## Análisis residual para determinar normalidad de Gauss

Se procede a determinar la existencia de normalidad en los residuos, mediante gráficos de probabilidad normal y el test Shapiro Wilk, obteniéndose los siguientes resultados.

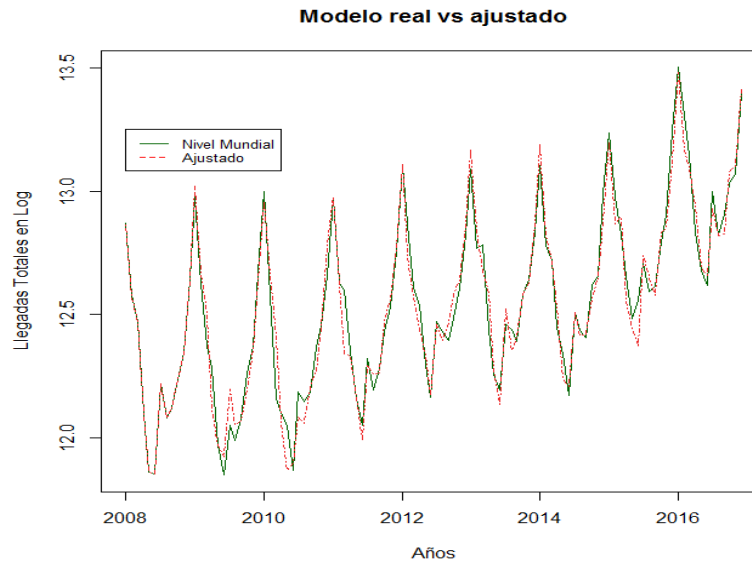
**GRAFICO 16: DETERMINACIÓN DE NORMALIDAD MEDIANTE CUANTILES PARA LLEGADA DE TURISTAS MUNDIALES DURANTE 2008 AL 2016.**



Gráficamente se aprecia que hay desviaciones en las colas de la distribución, por ende no se cumpliría el supuesto de la normalidad, no obstante se aplicó el test de Shapiro Wilk a un nivel de significancia del 5% el cual determinó que no existe normalidad en los residuales.

## Resultados del modelo aplicado para la llegada de turistas a nivel mundial

A continuación se presentan los resultados del modelo ajustado para la serie analizada, además se valora el gráfico de la serie real en conjunto a la serie estimada por el modelo aplicado.



Información del modelo:

**TABLA 3: COEFICIENTES DEL MODELO APLICADO**

SARIMA(2,1,3)(1,1,0) <sub>12</sub>	AR(1)	AR(2)	MA(1)	MA(2)	MA(3)	SAR(1)
Parámetros	-0,8389	-0,7374	0,3775	0,2474	-0,6355	-0,4662
Desviaciones estándar	0,1291	0,1145	0,1254	0,1129	0,0926	0,0974

**TABLA 4: BONDADES DE AJUSTES DEL MODELO**

Errores de medición	MAPE (%)	MAD	MSD	Varianza
Log	0,4267	0,0535	0,0750	0,0064
Anti log	1,5323	1,0550	1,077	1,0064

Se valoró el criterio de Akaike el cual es un estadístico basado en la teoría de información y las propiedades del método de máxima verosimilitud, para seleccionar el mejor modelo. Se determina un buen modelo el cual posee un menor valor de Akaike en comparación con otros. En nuestro caso el modelo entrega un Akaike de -190,93. El coeficiente de determinación del modelo resultó ser de 0,95.

Para determinar el poder predictivo del modelo, se determinó la predicción de noviembre del 2016 a febrero del 2017, obteniéndose los siguientes resultados.

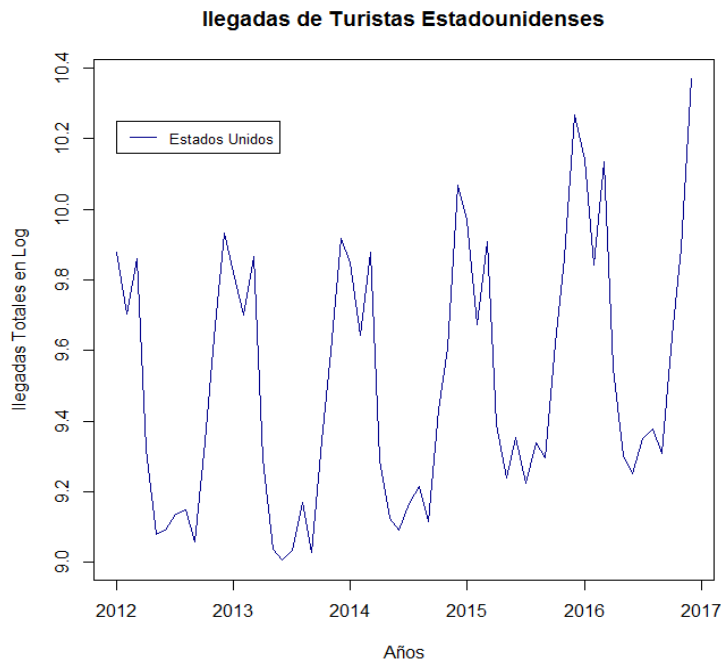
Serie Total Mundial	nov-16	dic-16	ene-17	feb-17
<b>Dato proyectado</b>	490.495	683.731	912.287	709.489
<b>Dato real</b>	474.278	657.823	964.027	709.043
<b>Variación real/proyectado</b>	<b>3,40%</b>	<b>3,90%</b>	<b>-5,30%</b>	<b>0,063%</b>

Se observa que las estimaciones de los meses de enero y febrero son bastante precisas según los totales reales, por otra parte al proyectar febrero usando los datos reales hasta el mes de enero del 2017, el error de pronóstico corresponde a una subestimación de un 2,4%. (Febrero ajustado 726.032)

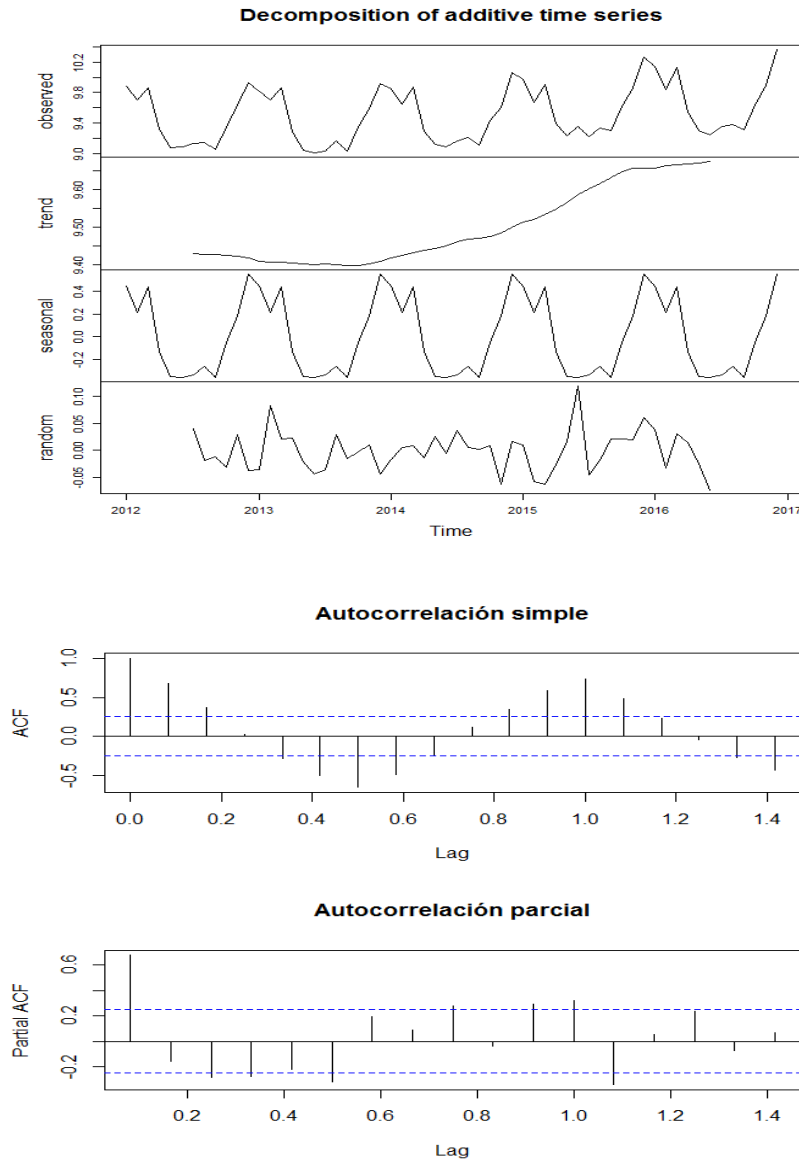
## Turistas estadounidenses

### Análisis mercado total de llegadas de turistas estadounidenses

GRAFICO 17: TENDENCIA DE LA LLEGADA DE TURISTAS A ESTADOUNIDENSES DURANTE 2012 AL 2016.




**GRAFICO 18: DESCOMPOSICIÓN DE LA SERIE DE LLEGADAS DE TURISTAS ESTADOUNIDENSES DURANTE 2012 AL 2016**



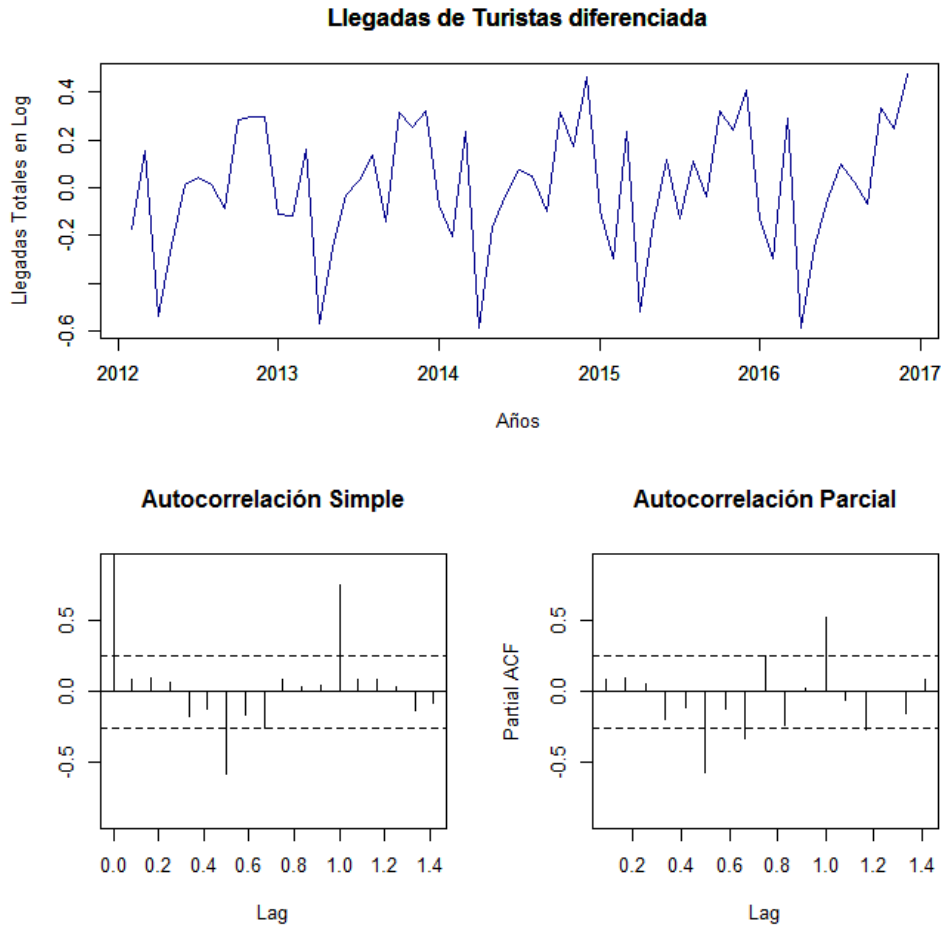
Se aprecian claras tendencias estacionales y de crecimiento durante los años de evolución histórica de la serie según el gráfico de lo observado y el comportamiento de su función de autocorrelación simple (ACF), a su vez, visualmente se ve un comportamiento estacional. Bajo estas circunstancias se procede a diferenciar el proceso para lograr que sea estacionario respecto a su tendencia y componente estacional.

GRAFICO 19: DIFERENCIACIÓN DE LA SERIE DE LLEGADAS DE TURISTAS ESTADOUNIDENSES DURANTE 2012 AL 2016.





**GRAFICO 20: AUTOCORRELACIÓN SIMPLE Y PARCIAL DE LA SERIE DE LLEGADAS DE TURISTAS ESTADOUNIDENSES DURANTE 2012 AL 2016.**




Se aprecia que en ambas funciones existe un rezago significativo para el rezago doceavo, lo cual evidencia la estacionalidad del comportamiento de esta serie temporal, además en la función de autocorrelación simple no se evidencia un comportamiento de caída exponencial en los primeros rezagos, sino más bien de medias móviles. Sin embargo al iterar modelos con las características sugeridas por ambas funciones, el modelo con mejor poder predictivo resultó ser SARIMA (2, 1,2) (1, 1,1)<sub>12</sub> estacional a 12 meses.

### Análisis residual para determinar autocorrelación serial

Una vez determinado lo anterior, se decide aplicar el modelo SARIMA (2, 1,2) (1, 1,1)<sub>12</sub> junto con su evaluación de los residuales con el fin de determinar existencias de autocorrelación para estos.

**GRAFICO 21: AUTOCORRELACIÓN Y DIAGNÓSTICO DE LOS RESIDUOS DE LA SERIE DE LLEGADAS DE TURISTAS ESTADOUNIDENSES DURANTE 2012 AL 2016.**




Gráficamente no se detecta el problema de la autocorrelación en los residuos de este modelo, sin embargo se procede a validar el supuesto mediante el test de autocorrelación de Ljung-Box el cual a un 5% de significancia determinó que no existe autocorrelación residual para el modelo.

### Análisis residual para determinar normalidad de Gauss

Se procede a determinar la existencia de normalidad en los residuos, mediante gráficos de probabilidad normal y el test Shapiro Wilk, obteniéndose los siguientes resultados.


**GRAFICO 22: DETERMINACIÓN DE NORMALIDAD MEDIANTE CUANTILES PARA LLEGADA DE TURISTAS ESTADOUNIDENSES DURANTE 2012 AL 2016.**



Gráficamente se aprecia que hay desviaciones en las colas de la distribución, por ende no se cumpliría el supuesto de la normalidad, no obstante se aplicó el test de Shapiro Wilk a un nivel de significancia del 5% el cual determinó que no existe normalidad en los residuales.

## Resultados del modelo aplicado para la llegada de turistas estadounidenses

A continuación se presentan los resultados del modelo ajustado para la serie analizada, además se valora el gráfico de la serie real en conjunto a la serie estimada por el modelo aplicado.



Información del modelo:

**TABLA 5: COEFICIENTES DEL MODELO APLICADO**

SARIMA(2,1,2)(1,1,0) <sub>12</sub>	AR(1)	AR(2)	MA(1)	MA(2)	SAR(1)	SMA(1)
<b>Parámetros</b>	-0,8975	-0,1164	0,4962	-0,5037	-0,0465	-0,5379
<b>Desviaciones estándar</b>	0,2615	0,2493	0,2283	0,2177	0,5555	0,6095

**TABLA 6: BONDADES DE AJUSTES DEL MODELO**

Errores de medición	MAPE (%)	MAD	MSD	Varianza
<b>Log</b>	0,0493	0,0355	0,0493	0.0031
<b>Anti log</b>	1,452	1,0361	1,0501	1.0030

Se valoró el criterio de Akaike el cual es un estadístico basado en la teoría de información y las propiedades del método de máxima verosimilitud, para seleccionar el mejor modelo. Se determina un buen modelo el cual posee un menor valor de Akaike en comparación con otros. En nuestro caso el modelo entrega un Akaike de -116,45. El coeficiente de determinación del modelo resultó ser de 0,98.

Para determinar el poder predictivo del modelo, se determinó la predicción de enero y febrero del 2017 a partir de los datos obtenidos hasta diciembre del 2016, obteniéndose los siguientes resultados.

Proyecciones USA		Intervalos 5% error		Valor real	
Meses	Totales	Inferior	Superior	Totales	variación
<b>Enero</b>	26.749	23.945	29.882	25.839	3,52%
<b>Febrero</b>	20.943	18.440	23.786	19.966	4,89%

Se verifica que el modelo sobre estima el periodo estival con una variación del 4% para enero del 2017 y sólo un 5% para febrero del mismo año. Lo cual se manifiesta una considerable precisión en las proyecciones obtenidas ya que en promedio el error estimado para el periodo estivas es de un 3,5%, indicando así una certeza a modo descriptivo del 96,5% para este periodo predicho.

## Turistas europeos

### Análisis mercado total de llegadas de turistas europeos.

GRAFICO 23: TENDENCIA DE LA LLEGADA DE TURISTAS EUROPEOS DURANTE 2008 AL 2016.





GRAFICO 24: DESCOMPOSICIÓN DE LA SERIE DE LLEGADAS DE TURISTAS EUROPEOS DURANTE 2012 AL 2016



Se aprecian claras tendencias estacionales y de crecimiento durante los años de evolución histórica de la serie según el grafico de lo observado y el comportamiento de su función de autocorrelación simple (ACF), a su vez, visualmente se ve un comportamiento estacional. Bajo estas circunstancias se procede a diferenciar el proceso para lograr que sea estacionario respecto a su tendencia y componente estacional.

GRAFICO 25: DIFERENCIACIÓN DE LA SERIE DE LLEGADAS DE TURISTAS EUROPEOS DURANTE 2012 AL 2016.

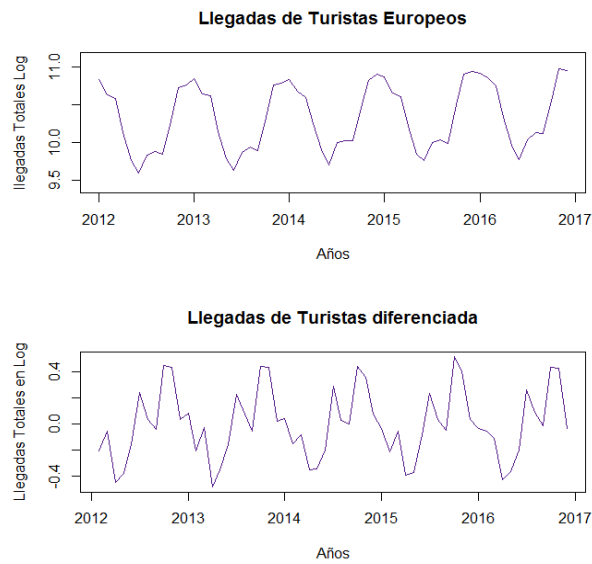
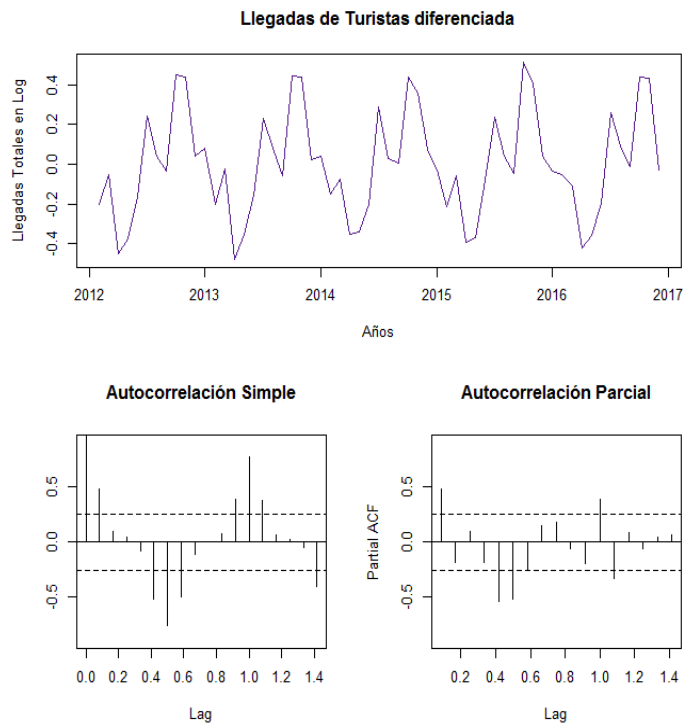


GRAFICO 26: AUTOCORRELACIÓN SIMPLE Y PARCIAL DE LA SERIE DE LLEGADAS DE TURISTAS EUROPEOS DURANTE 2012 AL 2016.

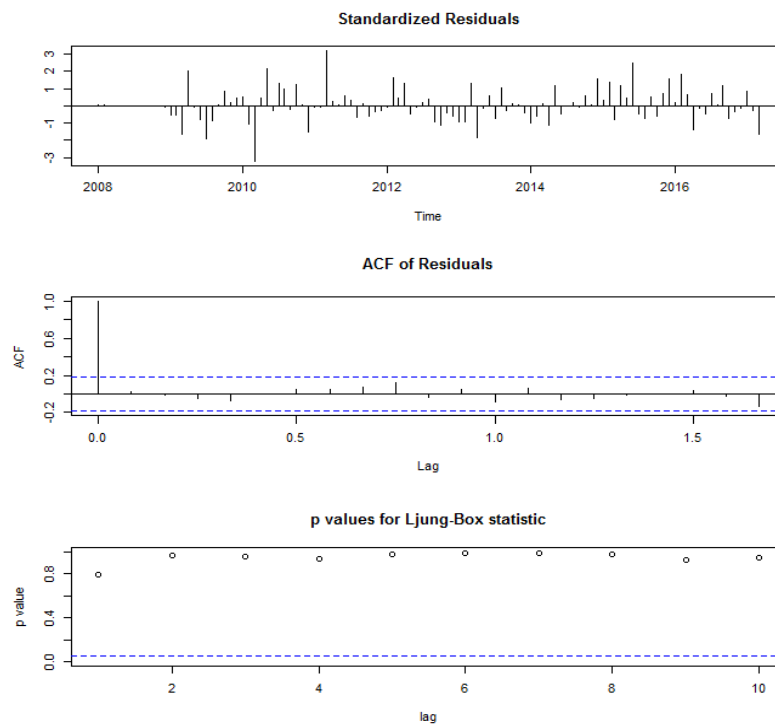


Se aprecia que en ambas funciones existe un rezago significativo para el rezago doceavo, lo cual evidencia la estacionalidad del comportamiento de esta serie temporal, además en la función de autocorrelación simple se evidencia un comportamiento de caída exponencial en los primeros rezagos, por ende se evidenciaría tendencia autorregresiva y de medias móviles. Al iterar modelos con las características sugeridas por ambas funciones, el modelo con mejor poder predictivo resultó ser SARIMA (2, 1,2) (1, 1,1)<sub>12</sub> estacional a 12 meses.

### Análisis residual para determinar autocorrelación serial

Una vez determinado lo anterior, se decide aplicar el modelo SARIMA (2, 1,2) (1, 1,1)<sub>12</sub> junto con su evaluación de los residuales con el fin de determinar existencias de autocorrelación para estos.

**GRAFICO 27: AUTOCORRELACIÓN Y DIAGNÓSTICO DE LOS RESIDUOS DE LA SERIE DE LLEGADAS DE TURISTAS EUROPEOS DURANTE 2012 AL 2016.**




Gráficamente no se detecta el problema de la autocorrelación en los residuos de este modelo, sin embargo se procede a validar el supuesto mediante el test de autocorrelación de Ljung box el cual a un 5% de significancia determinó que no existe autocorrelación residual para el modelo.



### Análisis residual para determinar normalidad de Gauss

Se procede a determinar la existencia de normalidad en los residuos, mediante gráficos de probabilidad normal y el test Shapiro Wilk, obteniéndose los siguientes resultados.


**GRAFICO 28: DETERMINACIÓN DE NORMALIDAD MEDIANTE CUANTILES PARA LLEGADA DE TURISTAS EUROPEOS DURANTE 2012 AL 2016.**



Gráficamente se aprecia que hay desviaciones en las colas de la distribución, por ende no se cumpliría el supuesto de la normalidad, no obstante se aplicó el test de Shapiro Wilk a un nivel de significancia del 5% el cual determinó que no existe normalidad en los residuales.

### Resultados del modelo aplicado para la llegada de turistas europeos

A continuación se presentan los resultados del modelo ajustado para la serie analizada, además se valora el gráfico de la serie real en conjunto a la serie estimada por el modelo aplicado.



Información del modelo:

TABLA 7: COEFICIENTES DEL MODELO APLICADO

SARIMA(2,1,2)(1,1,0) <sub>12</sub>	AR(1)	AR(2)	MA(1)	MA(2)	SAR(1)	SMA(1)
<b>Parámetros</b>	-0,7894	-0,2952	0,3678	0,1543	-0,0866	-0,9607
<b>Desviaciones estándar</b>	0,8607	0,5733	0,8783	0,4779	0,2347	21836

TABLA 8: BONDADES DE AJUSTES DEL MODELO

Errores de medición	MAPE (%)	MAD	MSD	Varianza
<b>Log</b>	0,2102	0,0218	0,0321	0,0013
<b>Anti log</b>	1,2339	1,0220	1,0326	1,0013

Se valoró el criterio de Akaike el cual es un estadístico basado en la teoría de información y las propiedades del método de máxima verosimilitud, para seleccionar el mejor modelo. Se determina un buen modelo el cual posee un menor valor de Akaike en comparación con otros. En nuestro caso el modelo entrega un Akaike de -146.23. El coeficiente de determinación del modelo resultó ser de 0,98.

Para determinar el poder predictivo del modelo, se determinó la predicción de enero y febrero del 2017 a partir de los datos obtenidos hasta diciembre del 2016, obteniéndose los siguientes resultados.


Proyecciones Europa		Intervalos 5% error		real	
Meses	Totales	Inferior	Superior	Totales	variación
<b>Enero</b>	60.079	55.614	64.904	61625	-2,51%
<b>Febrero</b>	49.885	45.645	54.518	50644	-1,50%

Se verifica que el modelo subestima el periodo estival con una variación del 2,51% para enero del 2017 y sólo un 1,5% para febrero del mismo año. Lo cual se manifiesta una considerable precisión en las proyecciones obtenidas ya que en promedio el error estimado para el periodo estivas es de un 2,5%, indicando así una certeza a modo descriptivo del 97,5% para este periodo predicho.


## Turistas brasileños

### Análisis mercado total de llegadas de turistas de Brasil.

GRAFICO 29: TENDENCIA DE LA LLEGADA DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016.




**GRAFICO 30: DESCOMPOSICIÓN DE LA SERIE DE LLEGADAS DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016**




Se aprecian claras tendencias estacionales y de crecimiento durante los años de evolución histórica de la serie según el grafico de lo observado y el comportamiento de su función de autocorrelación simple (ACF), a su vez, visualmente se ve un comportamiento estacional. Bajo estas circunstancias se procede a diferenciar el proceso para lograr que sea estacionario respecto a su tendencia y componente estacional.

**GRAFICO 31: DIFERENCIACIÓN DE LA SERIE DE LLEGADAS DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016.**



**GRAFICO 32: AUTOCORRELACIÓN SIMPLE Y PARCIAL DE LA SERIE DE LLEGADAS DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016.**

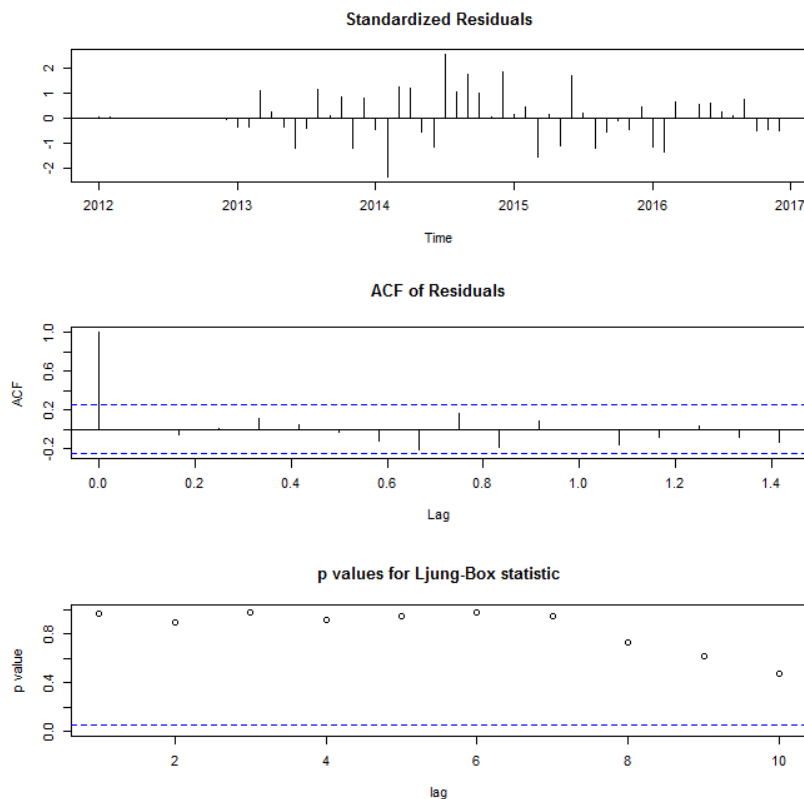


Se aprecia que en ambas funciones existe un rezago significativo para el rezago doceavo, lo cual evidencia la estacionalidad del comportamiento de esta serie temporal, además en la función de autocorrelación simple se evidencia un comportamiento sugerido a medias móvil y autorregresivo. Sin embargo al iterar modelos con las características sugeridas por ambas funciones, el modelo con mejor poder predictivo resultó ser SARIMA (2, 1,2) (0, 1,2)<sub>12</sub> estacional a 12 meses.

### Análisis residual para determinar autocorrelación serial

Una vez determinado lo anterior, se decide aplicar el modelo SARIMA (2, 1,2) (0, 1,2)<sub>12</sub> junto con su evaluación de los residuales con el fin de determinar existencias de autocorrelación para estos.

**GRAFICO 33: AUTOCORRELACIÓN Y DIAGNÓSTICO DE LOS RESIDUOS DE LA SERIE DE LLEGADAS DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016.**




Gráficamente no se detecta el problema de la autocorrelación en los residuos de este modelo, sin embargo se procede a validar el supuesto mediante el test de autocorrelación de Ljung box el cual a un 5% de significancia determinó que no existe autocorrelación residual para el modelo.

### Análisis residual para determinar normalidad de Gauss

Se procede a determinar la existencia de normalidad en los residuos, mediante gráficos de probabilidad normal y el test Shapiro Wilk, obteniéndose los siguientes resultados.


**GRAFICO 34: DETERMINACIÓN DE NORMALIDAD MEDIANTE CUANTILES PARA LLEGADA DE TURISTAS BRASILEÑOS DURANTE 2012 AL 2016.**



Gráficamente se aprecia que hay leves desviaciones en las colas de la distribución, no obstante se aplicó el test de Shapiro Wilk a un nivel de significancia del 5% el cual determinó que si existe normalidad en los residuales.

## Resultados del modelo aplicado para la llegada de turistas brasileños

A continuación se presentan los resultados del modelo ajustado para la serie analizada, además se valora el gráfico de la serie real en conjunto a la serie estimada por el modelo aplicado.



Información del modelo:

**TABLA 8: COEFICIENTES DEL MODELO APLICADO**

SARIMA(2,1,2)(0,1,2) <sub>12</sub>	AR(1)	AR(2)	MA(1)	MA(2)	SMA(1)	SMA(2)
<b>Parámetros</b>	0,6535	0,1581	-1,1737	0,1738	-0,7873	-0,2126
<b>Desviaciones estándar</b>	0,5264	0,3703	0,5321	0,5197	0,4108	0,2039

**TABLA 9: BONDADES DE AJUSTES DEL MODELO**

Errores de medición	MAPE (%)	MAD	MSD	Varianza
<b>Log</b>	0,6393	0,0663	0,0921	0,0111
<b>Anti log</b>	1,8952	1,0685	1,0965	1,0112

Se valoró el criterio de Akaike el cual es un estadístico basado en la teoría de información y las propiedades del método de máxima verosimilitud, para seleccionar el mejor modelo. Se determina un buen modelo el cual posee un menor valor de Akaike en comparación con otros. En nuestro caso el modelo entrega un Akaike de -46,82. El coeficiente de determinación del modelo resultó ser de 0,81.



Para determinar el poder predictivo del modelo, se determinó la predicción de enero y febrero del 2017 a partir de los datos obtenidos hasta diciembre del 2016, obteniéndose los siguientes resultados.

Proyecciones Brasil		Intervalos 5% error		real	
Meses	Totales	Inferior	Superior	Totales	variación
<b>Enero</b>	39.757	31.607	50.009	41229	-3,57%
<b>Febrero</b>	24.657	19.063	31.892	26062	-5,39%

Se verifica que el modelo subestima el periodo estival con una variación del 3,57% para enero del 2017 y un 5,39% para febrero del mismo año. Lo cual se manifiesta una considerable precisión en las proyecciones obtenidas ya que en promedio el error estimado para el periodo estivas es de un 4,5%, indicando así una certeza a modo descriptivo del 95,5% para este periodo predicho.

## Bibliografía

- Box, G. E. P. y Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day.*  
.-*Brockwell, P. J. y Davis, R. A. (1991). Time Series: Theory and Methods. [2ª edición]. Springer-Verlag.*  
.- *Brockwell, P. J. y Davis, R. A. (1996). Introduction to Time Series and Forecasting. Springer-Verlag.*

## Anexos

Pronósticos desde Marzo del 2017 a Marzo del 2018 según modelos detallados para cada mercado.



Forecast	Argentina	Intervalos 95%	
Meses	Point Forecast	Lo 95	Hi 95
Apr 2017	237.281	178.615	315.215
may-17	182.087	134.304	246.868
jun-17	139.462	100.921	192.725
jul-17	208.353	148.079	293.162
Aug 2017	191.394	133.717	273.950
sep-17	214.186	147.217	311.623
oct-17	269.507	182.362	398.296
nov-17	277.232	184.787	415.929
Dec 2017	420.925	276.523	640.741
Jan 2018	734.827	476.008	1.134.361
feb-18	510.206	326.055	798.356
mar-18	361.722	228.141	573.510




Forecast	Mundo	Intervalos 95%	
Meses	Point Forecast	Lo 95	Hi 95
Apr 2017	469,625	381.776	522.510
may-17	388.357	324.938	464.158
jun-17	387.965	320.898	469.053
jul-17	502.078	413.892	609.053
Aug 2017	440.392	358.011	541.728
sep-17	464.204	373.506	576.921
oct-17	533.818	427.731	666.217
nov-17	578.718	458.961	729.723
Dec 2017	809.377	636.029	1.029.970
Jan 2018	1.108.846	867.248	1.417.748
feb-18	863.665	669.918	1.113.446
mar-18	681.669	524.437	886.042

Forecasts	USA	Intervalos 95%	
Meses	Point Forecast	Lo 95	Hi 95
Apr 2017	14.207	12.669	15.930
may-17	11.528	10.160	13.081
jun-17	11.318	9.908	12.929
jul-17	11.654	10.108	13.437
Aug 2017	12.341	10.582	14.392
sep-17	11.413	9.677	13.460
oct-17	15.736	13.209	18.746
nov-17	20.062	16.685	24.122
Dec 2017	30.565	25.199	37.072
Jan 2018	26.333	21.529	32.210
feb-18	20.590	16.698	25.388
mar-18	25.234	20.306	31.357

Forecasts	Europa	Intervalos 95%	
Meses	Point Forecast	Lo 95	Hi 95
Apr 2017	31.684	29.446	34.093
may-17	22.066	20.293	23.994
jun-17	18.974	17.157	20.984
jul-17	24.358	21.745	27.284
Aug 2017	25.610	22.614	29.004
sep-17	24.810	21.671	28.402
oct-17	39.303	34.004	45.428
nov-17	59.170	50.727	69.018
Dec 2017	61.324	52.122	72.151
Jan 2018	62.672	52.840	74.335
feb-18	53.135	44.460	63.502
mar-18	49.852	41.412	60.013

Forecast	Brasil	Intervalos 95%	
Meses	Point	Lo 95	Hi 95
Apr 2017	31.670	25.435	39.433
may-17	31.359	24.507	40.127
jun-17	39.056	29.784	51.216
jul-17	61.905	46.421	82.556
Aug 2017	52.416	38.806	70.798
sep-17	41.806	30.646	57.029
oct-17	37.822	27.507	52.005
nov-17	31.632	22.854	43.780
Dec 2017	42.938	30.853	59.756
Jan 2018	44.490	31.810	62.227
feb-18	28.156	20.069	39.501
mar-18	29.575	21.026	41.598







Gobierno  
de Chile

[www.gob.cl](http://www.gob.cl)

Subsecretaría  
de Turismo

Gobierno de Chile

SERNATUR  
Ministerio de  
Economía, Fomento y  
Turismo

Gobierno de Chile