



LOS LIBERTADORES  
FUNDACIÓN UNIVERSITARIA

# Metodología para incrementar la precisión en la estimación del volumen de llamadas en los centros de contacto del sector de telecomunicaciones a través de modelos de series de tiempos en el proceso de Workforce Management

Alexandra Pacheco Gómez  
Especialización en estadística aplicada, Fundación Universitaria los Libertadores;  
Ingeniera Industrial, Corporación Universitaria Minuto de Dios.

## Resumen

Un pronóstico de llamadas entrantes errado puede llevar al exceso o escasez de agentes, lo que se traduce en pérdidas para el negocio o insatisfacción del cliente por lo que se busca diseñar y validar un modelo estadístico óptimo de pronóstico que se ajuste a los requerimientos del tráfico real y que maneje los supuestos teórico-prácticos de series temporales que permita la optimización de recursos en términos de talento humano. Se utilizó la metodología estadística de Box-Jenkins basada en series de tiempos para la creación de un modelo de pronóstico el cual se comparó con el modelo tradicional utilizado actualmente en el proceso Workforce. Se logró construir una metodología estadística que aporta valor al proceso y su capacidad para caracterizar el comportamiento de las llamadas entrantes cuenta con sustento estadístico lo que conlleva a un mejor control en la estimación de recursos, lo que permitirá aumentar la eficiencia y la confiabilidad en el proceso de dimensionamiento.

## Abstract

An erroneous inbound call forecast can lead to excess or shortage of agents, which translates into business losses or customer dissatisfaction. Therefore, we seek to design and validate an optimal statistical forecasting model that adjusts to the real traffic requirements and that handles the theoretical-practical assumptions of time series that allows the optimization of resources in terms of human talent. The Box-Jenkins statistical methodology based on time series was used to create a forecast model which was compared with the traditional model currently used in the Workforce process. It was possible to build a statistical methodology that adds value to the process and its ability to characterize the behavior of incoming calls is statistically supported, which leads to a better control in the estimation of resources, which will increase efficiency and reliability in the staffing process.



## Palabras Clave

*WorkForce  
Pronóstico  
Dimensionamiento  
Serie de Tiempos  
Estadística  
Estacionariedad  
Centro de Contacto*



## Key Words

*WorkForce  
Forecasting  
Sizing  
Temporal Series  
Statistics  
Stationarity  
Call Center*

## 1. Introducción

Actualmente todos los negocios están interesados en prestar cada uno de sus servicios de la manera más eficiente posible para brindar una experiencia al cliente de calidad, pero al mismo tiempo hacerlo con el menor uso de recursos posible y los centros de contacto no son la excepción, Arevalo (2014) afirma que “para el buen funcionamiento de un centro de contacto y solución, deben realizarse proyecciones acertadas del tráfico de las llamadas que van a ingresar a las líneas telefónicas y de igual manera debe programarse eficazmente al personal. Una mala planificación puede llevar al exceso o escasez de agentes, lo que se traduce en pérdidas para el negocio e insatisfacción en el caso de servicio al cliente.

En estos entornos, los modelos operativos tradicionales son de gran valor y al mismo tiempo limitados en su capacidad para caracterizar el comportamiento de las llamadas en los centros de contacto (Gans, 2003, p. 79) por lo que se hace necesario complementar estas metodologías y ajustarlas a las necesidades propias de los centros de contacto. Además, la falta de una metodología de referencia puede generar confusiones y grandes diferencias en las estimaciones de un mismo proceso -Workforce-” (p. 94).

La fuerza de trabajo o Workforce Management, según Koole 2013 (como se citó en Ding 2016) es el nombre comúnmente utilizado para referirse al ciclo de planificación que resulta en la programación de los turnos y agentes de un centro de contacto, para diferentes periodos de tiempo y se compone de las siguientes cuatro etapas:

**Forecasting.** Análisis y estimación de la demanda en este caso de llamadas en un determinado periodo de tiempo.

**Staffing.** Determinación y dimensionamiento de la capacidad o de los recursos necesarios para satisfacer la demanda o el número de llamadas.

**Scheduling.** Definición del número óptimo de recursos necesarios en intervalos de tiempo.

**Rostering.** Planificación y programación acertada de turnos. (p. 2).

En este proyecto nos vamos a centrar en la Etapa del Forecasting del proceso de Workforce Management ya que es un paso crucial para llevar a cabo un correcto dimensionamiento y la correcta distribución de turnos necesarios en los diferentes intervalos de tiempo para brindar un servicio al cliente de calidad, porque una mala planificación del volumen de llamadas desencadena consecuencias financieras negativas si presentamos déficit o exceso de recursos.

También existen variables adicionales que sesgan el proceso actual de WorkForce como lo plantea Arévalo (2014): “Cada analista WorkForce realiza las proyecciones de una manera diferente según sus conocimientos, experiencia y suposiciones; es decir, a la variabilidad natural de los procesos, se está agregando un sesgo adicional que depende de las personas que están realizando las proyecciones” (p. 96)

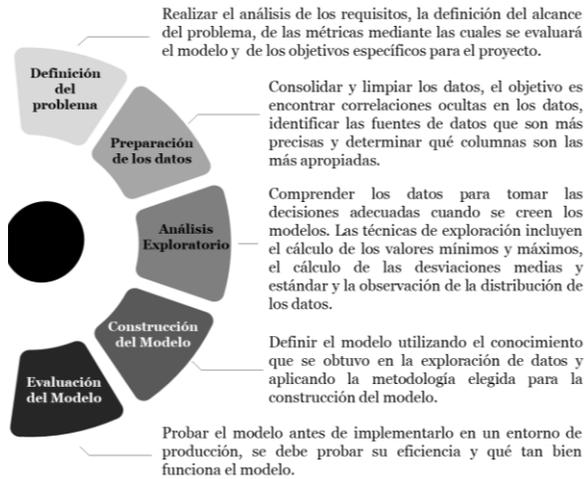
Por lo que se hace necesario encontrar un Modelo Estadístico propio de cada cliente que se estandarice y permita identificar el comportamiento de las llamadas que arriban a los centros de contacto y con esto apalancar las metodologías matemáticas empíricas tradicionales que aún se siguen utilizando en los centros de contacto desde el área WorkForce para la proyección del comportamiento del tráfico de llamadas que posiblemente arribara a la central telefónica, metodologías que actualmente aportan valor al proceso pero su capacidad para caracterizar el comportamiento de las llamadas sigue siendo limitada y carecen de sustento estadístico.

Lo que se quiere lograr con la creación y aplicación de modelos estadísticos autorregresivos (AR) y de medias móviles (MA) de la metodología Box-Jenkins a nuestros datos es comparar los resultados de estos modelos versus los resultados de la composición ponderada de los modelos tradicionales de suavización exponencial simple, tipo de día y combinación lineal para encontrar cual permite obtener una mejor precisión en datos proyectados para el mes de octubre del año 2022 y así elegir y utilizar el que permita una mejor toma de decisiones en cuanto a la solicitud de recursos para satisfacer la demanda de llamadas.

## 2. Métodos

La metodología utilizada para este estudio esta basada en los pasos clave del proceso para la construcción de un modelo de minería de datos de Microsoft (Microsoft, 2022) la cual se ilustra en la figura 1.

**Figura 1.**  
Esquema metodológico para el análisis de datos



Nota: Esquema modificado a partir de la metodología de Microsoft de conceptos de minería de datos (Microsoft, 2022).

Los métodos tradicionales para la planificación de las llamadas entrantes que se utiliza actualmente carece de sustento estadístico por lo que se hace necesario la aplicación de modelos estadísticos bajo la Metodología Box Jenkins la cual representa el comportamiento de una serie de tiempos y con estos resultados comparar que modelo tiene una mejor estimación de llamadas, para esto se emplea una base de datos de llamadas recibidas en el periodo de enero de 2020 a octubre de 2022 en un centro de contacto, la cual tendrá un tratamiento de limpieza de datos y diferencias para eliminar datos atípicos, tendencias y estacionalidad, para así realizar la construcción del modelo sobre una base de datos más precisa.

### 2.1. Definición del problema

La predicción de llamadas entrantes tradicionalmente se realiza siguiendo la metodología de composición ponderada de tres diferentes modelos como se muestra en la formula número 1.

$$t_x = Px_1 * \text{Suavización Exponencial Simple} + Px_2 * \text{Tipo de día} + Px_3 * \text{Combinación Lineal}$$

Formula 1. Modelo tradicional para pronóstico de llamadas.

Donde:

$t_x$ : Es el dato que se busca pronosticar por día.

$Px_i$ : Dato en porcentaje (%) y es la participación o peso que se elige para cada uno de los modelos, este porcentaje de participación es modificado por el analista Workforce a cargo a partir de sus conocimientos sobre la línea, experiencia y suposiciones.

**Suavización Exponencial Simple:** Se promedian las últimas siete interacciones de cada uno de los días, la última interacción más reciente, el promedio con el peso de las últimas cuatro interacciones del más reciente al más antiguo con un 10%, 20%, 30% y 40% respectivamente, el promedio entre la mediana y resultado del promedio de las siete interacciones, promedio de las últimas 3 interacciones a cada uno de estos resultados se les aplica un porcentaje de participación 30%, 25%, 15%, 20% y 10% respectivamente, se les calcula la mediana y el promedio y a partir de estos datos calculamos la proyección final.

**Tipo de día:** En este modelo se usan los pesos de cada una de las combinaciones y adicional se le aplica un promedio adicional con el peso de las últimas interacciones del mismo día del más reciente al más antiguo con un 10%, 20%, 30% y 40% respectivamente.

**Combinación Lineal:** Es el modelo que se obtiene con la ponderación de las combinaciones de cada registro, según tipo de día, número de semana del mes y número del mes, así como días festivos y días después de festivos. Con la ponderación de cada combinación se proyecta el día que coincida con dicha combinación y esto genera el modelo. Finalmente, el analista Workforce aplica un sesgo adicional al pronóstico teniendo en cuenta ofertas comerciales compartidas por el cliente de cada línea de negocio, siendo esta la variable más difícil de modelar con las series de tiempo.

La misma proyección de llamadas se puede lograr por medio del uso de modelos univariantes autorregresivos (AR) y de medias móviles (MA) de la metodología de Box Jenkins la cual

básicamente consiste en encontrar un modelo matemático que represente el comportamiento de una serie temporal de datos, y permita hacer previsiones únicamente introduciendo el período de tiempo correspondiente. En los modelos ARIMA univariantes se explica el comportamiento de una serie temporal a partir de las observaciones pasadas de la propia serie y a partir de los errores pasados de previsión (Jiménez et al., 2006, p. 187).

El que se va a utilizar en este artículo es el modelo SARIMA ya que los datos son de tipo univariados, presentan tendencia y ciclicidad por semana y en algunos intervalos por mes por lo que se requiere no solo la aplicación de diferencias ordinarias sino también la aplicación de diferencias estacionarias para la eliminación de ciclos. La notación compacta de modelo SARIMA es la siguiente:

ARIMA (p, d, q) x (P, D, Q), donde (p-P) es el número de parámetros autorregresivos, d es el número de diferenciaciones ordinarias para eliminar tendencia para que la serie sea estacionaria, D es el número de diferenciaciones estacionarias para eliminar estacionalidad para que la serie sea estacionaria y (q-Q) es el número de parámetros de medias móviles (Jiménez et al., 2006).

Lo que se busca en este artículo es comparar los resultados de ambas metodologías de pronósticos para aplicar la que mejor predice las llamadas entrantes en la fase de Forecasting del proceso de Workforce Management.

## 2.2. Descripción y preparación de los datos

Para cumplir el objetivo de comparar los métodos tradicionales versus los métodos de series de tiempo se cuenta con una base de datos con 760 interacciones, correspondiente a las llamadas recibidas en el periodo de enero de 2020 a octubre de 2022 de un centro de contacto. Para la implementación de los modelos de pronóstico del volumen de llamadas entrantes se tomará una muestra experimental desde el 01 de enero del 2020 hasta el 30 de septiembre del 2022, dejando así el mes de octubre como muestra de

comprobación de los modelos para medir que tan bien están estimando las llamadas entrantes.

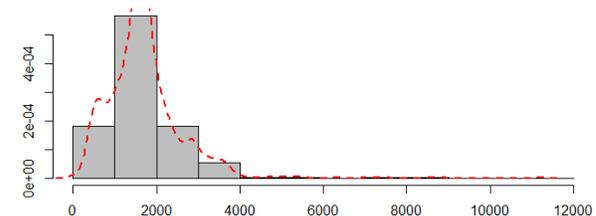
En esta investigación también se garantizará que las bases de datos pasen por un estricto proceso de limpieza de datos, data cleaning o scrubbing, que es un proceso necesario para asegurar la calidad de los datos que se emplearán para el análisis, este paso es fundamental para minimizar el riesgo que supondría el basar la toma de decisiones en información poco precisa, errónea o incompleta.

Para llevar a cabo este proceso de limpieza de datos se usarán medidas de tendencia central como la media, moda y mediana, medidas de dispersión como el rango de variación, la desviación estándar y el coeficiente de variación, gráficos de tendencia central y de dispersión como histogramas, boxplot y diagramas de dispersión.

**Tabla 1.** Resultados de los estadísticos aplicados a la base de llamadas entrantes.

Estadísticos llamadas entrantes			
Media	1.724	Cuartil 1	1.197
Moda	1.631	Cuartil 2	1.604
Mediana	1.604	Cuartil 3	2.003
Mínimo	0	Cuartil 4	11.214
Máximo	11.214	Varianza	976.315
Desviación	988	Coficiente Variación	57,32%

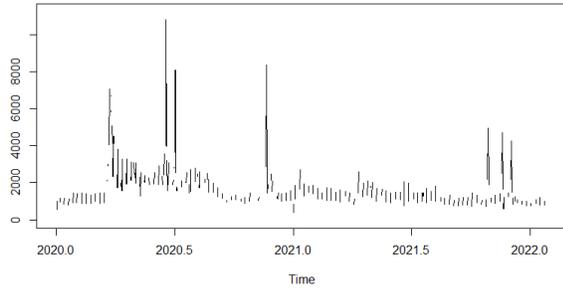
**Figura 2.** Distribución de los datos de llamadas entrantes.



La distribución de los datos de llamadas entrantes presenta un sesgo a la izquierda, como lo muestra la gráfica 1 y en la tabla 1 los resultados de la media y la mediana lo confirman, existen datos atípicos hacia el cuartil 4 y tenemos un mínimo de cero lo cual está dado por la propia naturaleza de la línea.

La gráfica 3 describe en que puntos y con que regularidad se repiten o se encuentran los datos atípicos de llamadas entrantes.

**Figura 3.**  
Cantidad de llamadas que ingresan por día al centro de contacto telefónico.



Se toma la decisión de sustituir los días 19 de junio, 3 y 19 de julio del año 2020, 28 de octubre, 19 de noviembre y el 3 de diciembre del año 2021, 11 de marzo y 17 de junio del año 2022 por los promedios de los mismos días de la semana del mismo mes (promedio de lunes, promedio de martes, etc.), esto porque la línea es de la tipología de ventas y los días sin Iva hacen que estas llamadas aumenten más del doble lo que nos genera un comportamiento atípico y como el mes que se desea pronosticar no tiene esta tipología de días no se requieren estos comportamientos.

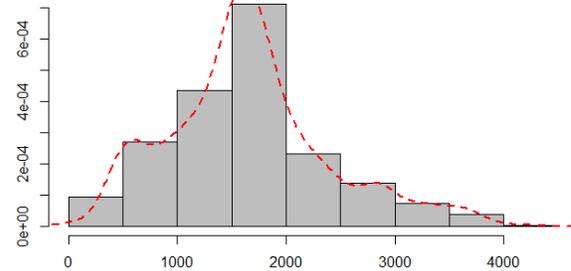
Adicional se reemplazan todos los 1 de enero de cada año por el promedio del mismo día de la semana, ya que la línea no tiene gestión estos días por lo que no se requiere un pronostico para este y un cero también genera un sesgo atípico en la distribución.

Con estas modificaciones se ajusta la distribución de los datos acercándose a una distribución normal, comportamiento que se puede evidenciar en la figura 4 y con los resultados en la tabla 2 de la media y la mediana que están ahora más cercanas entre sí, adicional se debe tener en cuenta que el comportamiento y la tendencia; a medida que pasan los años; del tráfico por esta línea ha disminuido lo que presenta un número alto de llamadas al inicio de la serie de tiempo y se puede llegar a ver como datos alejados o atípicos hacia la derecha de la media, como se muestra en la figura 4.

**Tabla 2.**  
Resultados de los estadísticos aplicados a la base de llamadas entrantes sin valores atípicos.

Estadísticos llamadas entrantes			
Media	1.659	Cuartil 1	1.204
Moda	1.631	Cuartil 2	1.604
Mediana	1.604	Cuartil 3	2.003
Mínimo	216	Cuartil 4	11.214
Máximo	4.193	Varianza	537.978
Desviación	733	Coefficiente Variación	44,2%

**Figura 4.**  
Distribución de los datos de llamadas entrantes sin valores atípicos.



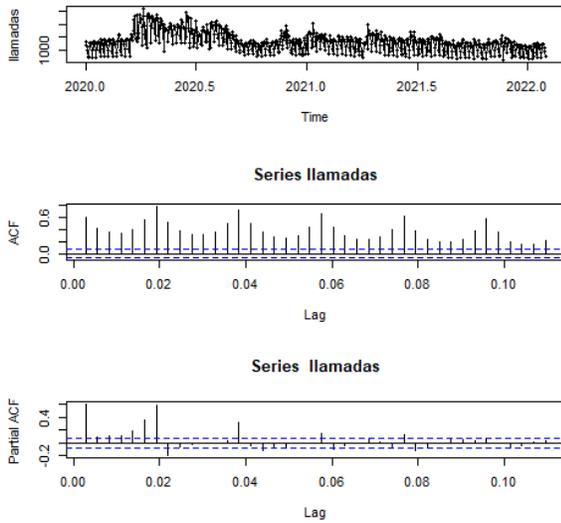
### 2.3. Análisis Exploratorio

Para la aplicación de la Metodología de Box Jenkins se necesita contar con una serie temporal de datos y que esta tenga un comportamiento estacionario es decir que cuente con una Media y una Varianza constante de no ser así se procede a identificar si existe tendencia y estacionalidad para eliminarlas mediante las diferencias ordinarias y estacionales respectivamente para convertir la serie de tiempo en estacionaria.

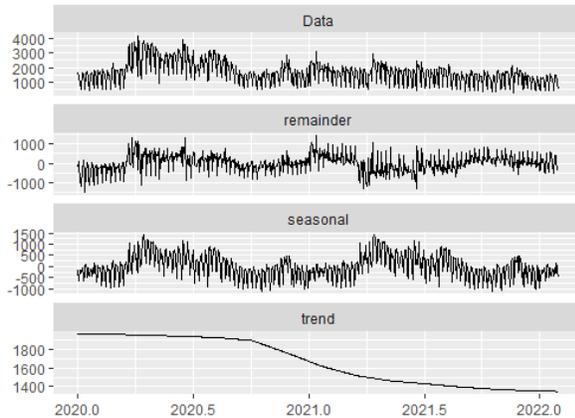
Para la identificación de la tendencia, variabilidad, estacionariedad y si existe ciclicidad en la base de datos se hace uso de gráficos de representación de puntos, gráfico de descomposición, gráficos de ACF y PACF y criterios técnicos como pruebas de Dickey – Fuller, Phillips Perron y Dickey – Fuller aumentada.

La serie de datos tiende a exhibir comportamientos repetitivos, con ciclos que se repiten regularmente que son fácilmente visibles en la figura 5 y en la descomposición de la serie, véase figura 6, también se evidencia la presencia de estacionalidad y de tendencia en este caso a la baja.

**Figura 5.** Identificación de tendencia, ciclicidad y estacionariedad en la base de llamadas entrantes.



**Figura 6.** Descomposición de la serie de llamadas entrantes.



Como se identificó en la gráfica 5 y 6 la presencia de tendencia y ciclos repetitivos en los datos se aplica a la serie de tiempos una diferencia ordinaria “diff(Base)”, una diferencia estacional “diff(Base,1)” y la combinación de las dos “diff(diff(Base,1))”, según los resultados de las

pruebas de estacionariedad de Dickey-Fuller, Phillips Perron y Dickey-Fuller aumentada del paquete urca que se muestran en la tabla 3 cualquiera de las diferencias logra volver estacionaria la serie de tiempo, aunque la diferencia estacional no pasa la prueba de Dickey-Fuller, en la figura 7 el ACF muestra que la diferencia estacional es la que mejor elimina tendencia y ciclicidad porque son pocas las barras que sobresalen del límite.

**Tabla 3.** Resultados de las pruebas de estacionariedad.

Base / p-value	Dickey-Fuller	Phillips Perron	Urca
<b>Base Original</b>	0,26	0,01	<b>-0,75</b>
<b>d Ordinaria</b>	0,01	0,01	-14,40
<b>D Estacional</b>	<b>0,19</b>	0,01	-1,87
<b>(D,d) Ordianria - Estacional</b>	0,01	0,01	-10,12

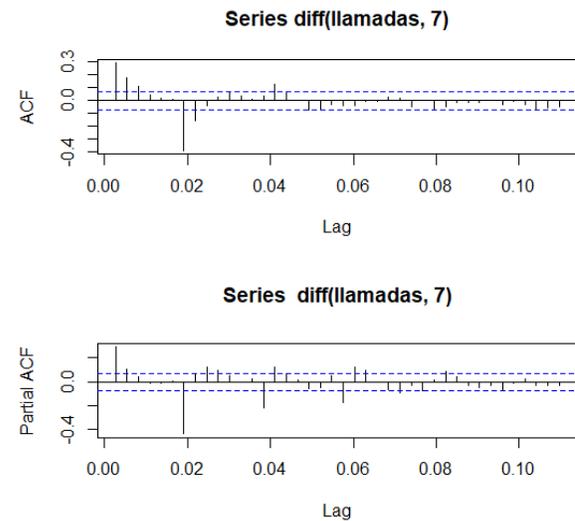
Las hipótesis que se formulan para los resultados de la Tabla 3 son las siguientes:

$$H_0 = \text{La serie de tiempo no es estacionaria}$$

$$H_1 = \text{La serie de tiempo es estacionaria}$$

El objetivo es rechazar  $H_0$  por que se busca que la serie de tiempo sea estacionaria y los resultados de p-value para Dickey -Fuller y Phillips Perron para rechazar deben ser menores a 0,05 y para la prueba de Urca deben ser menores a -1,95.

**Figura 7.** Aplicación de diferencias ordinarias y estacionales base de llamadas entrantes.



## 2.4. Construcción de los Modelos de serie de tiempos

La identificación del modelo se logra a través de los gráficos de ACF y PACF, para un modelo AR se identifica en el PACF a partir de los p-rezagos es decir la cantidad de líneas que sobresalen del límite y en el ACF se debe evidenciar una disminución o decaimiento exponencial, para identificar un modelo MA se hace con el ACF con los q-rezagos es decir el número de líneas que sobresalen sobre el límite y en el PACF se debe identificar un decaimiento exponencial alternados entre los dos ejes, esta propiedad teórica también aplica para los modelos combinados ARIMA y SARIMA pero a estos se les agrega las diferencias ordinarias y estacionales.

Una vez identificados los modelos a partir de la figura 7, se realiza el ajuste a cada uno revisando cuales coeficientes son significativos con las probabilidades estadísticas de estos, los que sean mayores a 0,05 son los coeficientes que se descartan del modelo es decir no son significativos y se crea un modelo más ajustado a la curva de los datos históricos, con esto obtenemos el modelo SARIMA (5, 0, 1) x (0, 1, 0) y el modelo SARIMA (7, 0, 1) x (2, 1, 1).

## 2.5. Evaluación de los Modelos de serie de tiempos

Se realizan las pruebas con el BIC buscando el menor dato, entre menor BIC mejor es el ajuste del modelo.

Adicional se realiza la evaluación de los modelos con las gráficas del comportamiento y las pruebas de autocorrelación, aleatoriedad y normalidad sobre los residuales de cada uno de los modelos, los cuales deben asemejarse a un ruido blanco, es decir media cero y varianza constante.

**Test de Autocorrelación** de Lyun – Box (Box.test()), se busca que no haya autocorrelación serial porque de lo contrario se rechaza el modelo.

$$H_0 = \text{No hay autocorrelación serial}$$

$$H_1 = \text{Si hay autocorrelación serial}$$

El objetivo es no rechazar  $H_0$  porque se busca que los residuales del modelo no estén correlacionados entre sí, los resultados de p-value para no rechazar deben ser mayores a 0,05.

**Test de aleatoriedad** (runs.test(as.factor())) en esta prueba se busca que los residuales tengan comportamiento aleatorio de lo contrario se descarta el modelo.

$$H_0 = \text{Los residuales son aleatorios}$$

$$H_1 = \text{Los residuales no son aleatorios}$$

El objetivo es no rechazar  $H_0$  porque se busca que los residuales del modelo sean aleatorios, los resultados de p-value para no rechazar deben ser mayores a 0,05.

**Test de Normalidad** (jarque.bera.test()) el cual está basado en sesgo y curtosis, el objetivo es que los residuales tengan una distribución normal, pero si los residuales no son normales no necesariamente se descarta el modelo.

$$H_0 = \text{Los residuales son normales}$$

$$H_1 = \text{Los residuales no son normales}$$

El objetivo es no rechazar  $H_0$  porque se busca que los residuales del modelo tengan una distribución normal, los resultados de p-value para no rechazar deben ser mayores a 0,05.

**Tabla 4.**  
Resultados de las pruebas aplicados a los residuales.

Base p-value	BIC	Lyun Box	Runs test	Normalidad
<b>Modelo 1</b>	11.408	2,8E-12	0,09	2,20E-16
<b>Modelo 2</b>	11.075	0,54	0,11	2,2E-16

El Modelo 1 “SARIMA (5, 0, 1) x (0, 1, 0)” no paso ninguna de las pruebas como se puede comprobar en los resultados de la tabla 4, pero el Modelo 2 “SARIMA (7, 0, 1) x (2, 1, 1)” paso dos de las pruebas que son imperativas para elegir el modelo y no se descarta así no haya pasado la prueba de Normalidad la cual no es causa de rechazo.

Finalmente, se elige pronosticar con el Modelo SARIMA (7, 0, 1) x (2, 1, 1) que es el que tiene mejor ajuste a los datos originales y es el que presenta los mejores resultados.

### 3. Resultados

El pronóstico se realizó con ambas metodologías para el mes de octubre del 2022 las cuales se compararon con los datos reales de este mismo mes (Tabla 5).

**Tabla 5.**  
Resultados de los modelos tradicionales versus los resultados del modelo SARIMA

Fecha	Real	Metodología Tradicional	Variación	Metodología Box-Jenkins	Variación
1/10/2022	630	656	4%	729	16%
2/10/2022	320	347	9%	326	2%
3/10/2022	1.055	1082	3%	1001	5%
4/10/2022	1.035	1048	1%	1061	3%
5/10/2022	1.026	1067	4%	1064	4%
6/10/2022	959	1016	6%	1003	5%
7/10/2022	855	931	9%	882	3%
8/10/2022	627	652	4%	666	6%
9/10/2022	309	348	13%	288	7%
10/10/2022	1.082	1065	2%	993	8%
11/10/2022	1.060	1045	1%	1083	2%
12/10/2022	1.003	1065	6%	1072	7%
13/10/2022	965	1025	6%	1024	6%
14/10/2022	934	945	1%	917	2%
15/10/2022	622	645	4%	687	11%
16/10/2022	287	348	21%	293	2%
<b>17/10/2022</b>	<b>401</b>	<b>535</b>	<b>33%</b>	<b>1012</b>	<b>152%</b>
18/10/2022	1.009	1060	5%	1098	9%
19/10/2022	1.048	1067	2%	1084	3%
20/10/2022	1.015	1014	0%	1038	2%
21/10/2022	993	947	5%	941	5%
22/10/2022	662	638	4%	704	6%
23/10/2022	372	340	9%	301	19%
24/10/2022	1.267	1193	6%	1028	19%
25/10/2022	1.100	1143	4%	1111	1%
26/10/2022	1.196	1135	5%	1097	8%
27/10/2022	1.038	1117	8%	1053	1%
28/10/2022	967	1044	8%	958	1%
29/10/2022	654	698	7%	718	10%
30/10/2022	356	384	8%	313	12%
31/10/2022	1.124	1182	5%	1042	7%

Los resultados del Modelo de Box-Jenkins tiene un ajuste bastante bueno en los días de lunes a sábado días hábiles y en el Domingo siendo un día festivo, pero no tiene en cuenta las tendencias de días festivos que estén entre lunes a sábado.

El pronóstico de llamadas entrantes del modelo tradicional tiene una variación en el mes de 2,65% versus el modelo de Box-Jenkins que tiene una variación de 0,02% contra el tráfico real, por lo que el modelo de Box-Jenkins es el que más se ajusta al comportamiento real de la línea por mes. Adicional se mide por día la variación de llamadas entrantes y el modelo que más se ajusta al real es el modelo tradicional con un 4,8% de variación versus el modelo de Box-Jenkins con un 6,1% de variación, pero tenemos casos como el 16, 27 y 28 de octubre donde el Modelo de Box-Jenkins tiene un mejor reflejo de la tendencia que el tradicional.

### 4. Conclusión

Se logro construir una metodología estadística que aporta valor al proceso y su capacidad para caracterizar el comportamiento de las llamadas entrantes cuenta con sustento estadístico lo que conlleva a un mejor control en la estimación de recursos en términos de talento humano necesarios para atender dicho tráfico lo que permitirá aumentar la eficiencia y la confiabilidad en el proceso de dimensionamiento.

En este caso se elaboró una metodología estadística que se ajusta muy bien a los días hábiles (lunes – sábado) y los días festivos (domingos) por lo que se recomienda utilizarse para la estimación de llamadas entrantes de estos días y para los festivos que estén entre lunes a sábado se debe utilizar la base solo con datos de días festivos para estimar el volumen de estos, así se contará con una estimación más precisa para estos días.

En esta metodología se demostró que a pesar de que se cimento bajo procesos estadísticos rigurosos, es lo suficientemente flexible, para incluir la composición entre los modelos tradicionales y el conocimiento, experiencia y suposiciones de los analistas Workforce del centro de contacto los cuales ayudan a apalancar los resultados de la estimación de llamadas entrantes.

A pesar de que se eliminaron los datos atípicos durante el proceso de la elaboración del modelo de pronóstico para no afectar la estimación, no significa que no se tengan en cuenta ya que pueden ser información valiosa, a estos datos atípicos se les debe dar el mismo tratamiento que a los días festivos de lunes a sábado, deben detectarse, realizar el seguimiento para determinar el por qué de su presencia y la afectación a futuras estimaciones y pronosticarse por medio de un modelo propio, con una base de solo datos atípicos.

Finalmente, se demostró que el modelo estadístico creado para la base de llamadas entrantes no se puede estandarizar ya que cada cliente requiere un modelo único debido a que cada uno tiene un tipo de tráfico que puede ser afectado por eventos aleatorios propios, pero la metodología Box-Jenkins en lo suficientemente flexible para permitir la implementación de varios modelos por lo que la metodología si se puede estandarizar en la etapa de Forecasting del proceso de Workforce Management.

## **5. Referencias**

- Arévalo, G. (2014, enero 11). Propuesta metodológica para incrementar la competitividad en los centros de contacto y solución telefónicos de empresas del sector de las telecomunicaciones a través del desarrollo del proceso Workforce Management. *Rev. esc.adm.neg*, volumen (76), pp. 92-127.
- Ding, S. (2016). *Workforce Management en Call Centers: Forecasting, Staffing y estudios empíricos*. [PhD-Tesis - Investigación y graduación interna, Vrije Universiteit Amsterdam].
- Jiménez, J.F.; Gázquez, J.C.; Sánchez, R. (2006, marzo 3). 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*, vol. 15, núm. 3, pp. 185-198.
- Microsoft (2022, junio 13). Conceptos de minería de datos. <https://learn.microsoft.com/en-us/analysis-services/data-mining/data-mining-concepts?view=asallproducts-allversions>
- Noah Gans, Ger Koole, Avishai Mandelbaum, (2003) Telephone Call Centers: Tutorial, Review, and Research Prospects. *Manufacturing & Service Operations Management* 5(2):79-141. <https://doi.org/10.1287/msom.5.2.79.16071>