

Caracterización de Intentos de Llamada del Servicio Móvil

Juan Manuel García y Pamela Medina *

Gerencia de Políticas Regulatorias

Organismo Supervisor de Inversión Privada en Telecomunicaciones | OSIPTEL

Resumen

El presente documento busca modelar la serie del número de intentos de llamada por hora que realizan los usuarios del servicio móvil. Mediante esta caracterización se puede deducir y predecir ciertos patrones de uso, los cuales son insumos esenciales para tomar decisiones del regulador sobre montos y desagregación de las tarifas y el establecimiento de indicadores regulatorios, así como promover nivel de inversión que permitan un dimensionamiento adecuado de la red, entre otros aspectos. La importancia del componente estacional de la serie es considerada para la estimación y se opta por utilizar un modelo SARIMA. Se encuentra que dicha especificación predice adecuadamente la mayor parte de la serie, con excepción de los puntos extremos, lo cual es esperable en el modelamiento de este tipo de series.

© 2008 OSIPTEL. Derechos reservados.

Palabras clave: Demanda, Intentos, Llamadas, Telecomunicaciones, Perú, Móvil.

*. El documento se ha beneficiado de los comentarios de José Gallardo y de Jorge Trelles. Las opiniones vertidas en este documento son de responsabilidad exclusiva de los autores y no reflejan necesariamente la posición del OSIPTEL. Remitir comentarios y sugerencias a: jgarcia@osiptel.gob.pe; pmolina@osiptel.gob.pe.

1. Introducción:

El conocimiento adecuado de la magnitud esperada de demanda de un producto o servicio es el elemento clave para el éxito de una empresa, ya que permite decisiones de inversión y de producción eficientes. En el caso de algunos servicios de consumo masivo con características monopólicas esta información es de interés tanto para las empresas reguladas como para que los organismos reguladores puedan realizar una supervisión adecuada. El conocimiento y anticipación del comportamiento de la demanda es crucial para decidir acerca de las inversiones en la red, así como el establecimiento de los indicadores regulatorios, y del monto y la desagregación de las tarifas.

Por ejemplo, tanto en la industria de energía eléctrica como en la industria de telecomunicaciones, la determinación de la hora cargada (basada a su vez en el proceso de la serie de demanda) define el adecuado dimensionamiento de la red, debido a que se busca que el sistema permita a los usuarios hacer uso del servicio siempre que ellos lo requieran. No obstante, la metodología de medición de la hora cargada puede ser en algunos casos un requisito muy estricto para la empresa; en tanto, el requerimiento que se presenta en dicha hora puede ser muy distante de lo ocurrido el resto del día o puede presentarse como un hecho atípico en lugar de un patrón normal de la demanda, en cuyo caso, esta petición resultaría poco económica. No obstante, ello sólo se podrá conocer una vez que se analice el comportamiento de la serie de intentos de llamada.

Por otro lado, las empresas operadoras pueden estar interesadas en discriminar sus tarifas tomando en cuenta horarios y para ello el conocimiento del patrón estacional de su demanda es fundamental. De la misma manera, las compañías comerciales usualmente siguen patrones trimestrales o anuales en actividades como pagos, control de inventarios, ofertas y promociones, entre otras, que deberían programarse también de acuerdo al patrón de la demanda.

Desde el punto de vista regulatorio, a los organismos supervisores del desempeño del mercado les interesa conocer los patrones estacionales de la serie de demanda para poder establecer indicadores de calidad o de otro tipo que garanticen la satisfacción

del usuario en función de las características inherentes al comportamiento del consumidor.

En el caso de la serie del total de intentos de llamada por hora en la industria de telefonía móvil, han aparecido múltiples documentos que realizan dichas estimaciones mediante diversas metodologías en los últimos años.

En nuestro caso, en vista de que no se cuenta con un número de datos suficiente para poder realizar un análisis más estructural, i.e., variables de las características socio-económicas de los usuarios, se utiliza la literatura actual en series de tiempo para escoger una forma de modelamiento que permita tomar en cuenta los patrones estacionales inherentes de este tipo de servicios de consumo masivo, los cuales se derivan de la propia actividad humana a lo largo del día, semana o mes. Para ello, se presenta una breve descripción de los modelos SARIMA y las estimaciones correspondientes junto a su bondad de ajuste y capacidad de predicción.

El documento consta de la siguiente estructura. En la siguiente sección se analiza de forma descriptiva las características de la serie de tal manera que se recoja mediante representaciones gráficas los patrones estacionales o de tendencia con los que la serie cuenta y que nos permitan escoger un modelo econométrico adecuado. En la sección 3, se revisa la literatura que ya ha tratado de modelar series de flujos de tráfico estacionales y se realizan las estimaciones correspondientes mediante modelos SARIMA. Posteriormente, en la sección 4 se corroboran las predicciones de la estimación con datos reales y finalmente se concluye en la sección 5.

2. Análisis descriptivo en base a una estación base de Lima que atiende una demanda moderada de llamadas¹

En la presente sección se pretende analizar el patrón de demanda por el servicio de telecomunicaciones móviles, para lo cual se cuenta con la serie de intentos de llamadas contabilizados por hora en una estación base promedio perteneciente, a su vez, a una estación controladora con una senda de consumo moderado de las empresas operadoras del sector. Por razones de confidencialidad, no es posible

¹. Alrededor del promedio observado para distintas estaciones.

trabajar con los valores reales de la serie, sino que se ha modificado la escala original de los datos. De otro lado, cabe decir que el análisis de la serie se ha realizado para el periodo comprendido entre el 1 de enero del 2007 hasta el 14 de agosto del mismo año. Se evita tomar en consideración el día del terremoto del 15 de agosto en adelante, para evitar sesgar la serie con los eventos atípicos ocurridos durante dicha semana.

En primer lugar, se realiza un análisis gráfico² de la serie con la finalidad de poder deducir patrones diario, semanal y mensual que nos muestre la estacionalidad de la serie original. Para ello, se trabajó específicamente con los datos provenientes a una estación controladora en Lima, asumiendo que ésta administraba un promedio de 40 estaciones base. Cabe decir que los gráficos presentados a continuación muestran el promedio de intentos de llamada dentro de la controladora en el rango temporal que se especifique.

a) Estacionalidad diaria


Para analizar el patrón diario de llamadas, se estimó los intentos promedio de llamadas por hora para el mes de septiembre del 2007 debido a que dicho mes permite una visión poco distorsionada de los resultados al no presentar feriados. Los datos se muestran en el gráfico No. 1. En él, los datos se muestran a lo largo de las 24 horas del día comenzando en la hora 1 que hace referencia al periodo entre las 12:00 pm y 01:00 am.

En primer lugar, se puede observar que el número de intentos de llamada en horario nocturno se distingue claramente del realizado en horario diurno pues existen aproximadamente ocho horas durante la noche que sostenidamente muestran promedios de intentos de llamadas bajos, mientras que las horas correspondientes al resto del día presentan promedios que van en aumento. Asimismo, se pueden identificar dos momentos importantes dentro del día en los cuales las llamadas alcanzan dos picos, a saber, entre las 12 del mediodía y 2 de la tarde y las 7 y 9 de la noche, siendo este último intervalo el que presenta el pico más alto del día.

². En todos los gráficos, se ha cambiado la escala tal que las etiquetas del eje de ordenadas representan proporciones, es decir, 3 resulta ser una cantidad que es el triple de la cantidad representada por 1 y de la misma manera los demás números. No necesariamente los mismos números representan las mismas cantidades alrededor de todos los gráficos.

De otro lado, analizando las desviaciones estándar se observa que dicho indicador va aumentando a medida que el número de intentos de llamada aumenta, debido a que en la noche el número de intentos de llamada es menor y mucho más estable para todas las estaciones base que conforman la controladora. Sin embargo, en el día, las diversas estaciones base pueden diferir en las horas más cargadas del día por localizarse en distritos con patrones disímiles de llamadas, lo cual aumenta la varianza durante el transcurso del mismo.

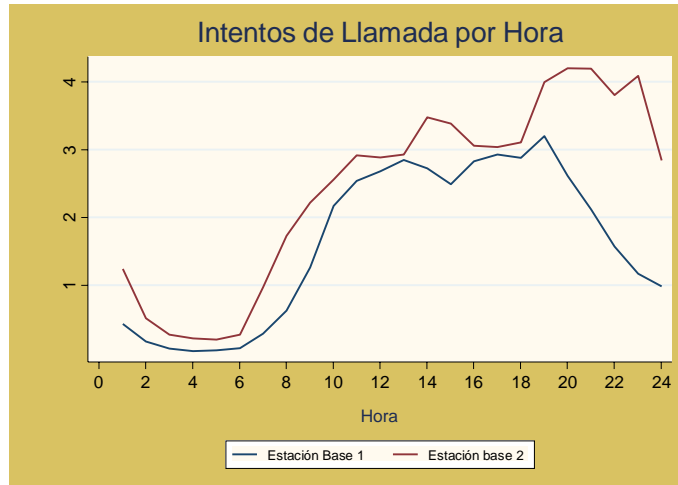
Gráfico No. 1:



Fuente: Empresas operadoras. Elaboración propia.

Es importante mencionar que el patrón mostrado anteriormente se repite también a nivel de estaciones base particulares, con variaciones específicas que suceden durante el día en dichas estaciones base. Por ejemplo, en el gráfico No. 2 se muestran los intentos de llamada en un día promedio para dos estaciones bases pertenecientes a la controladora en análisis que, si bien no coinciden exactamente en el número total de intentos de llamada, su distribución no difiere significativamente durante gran parte del día.


Gráfico No. 2: Dos estaciones base particulares



Fuente: Empresas operadoras. Elaboración propia.

Por otro lado, se trabajó también con la serie de máximos intentos de llamada por hora a nivel de estación base para conocer si es que en ellos también existe un patrón estacional. Así, podemos observar en el gráfico No. 3. el comportamiento muy similar de esta serie con respecto a la serie original de intentos de llamada, presentando los dos máximos locales y la diferencia entre el horario nocturno y el diurno. No obstante, en este caso se puede apreciar que todas estas diferencias se presentan de manera más pronunciada a lo largo del día, mostrándose así quiebres con pendientes mayores.

Gráfico No. 3:

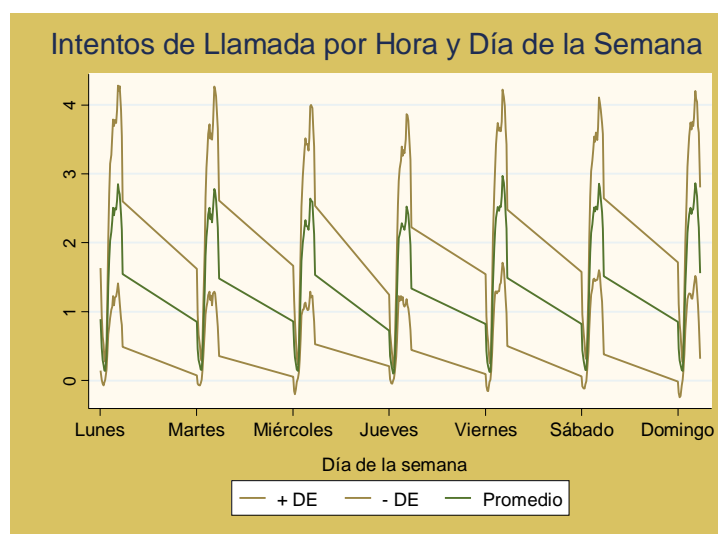


Fuente: Empresa operadora. Elaboración propia.

b) Estacionalidad semanal

Si se analiza el promedio de intentos de llamada por semana, podemos encontrar que estos tienden a ser mayores al inicio de la semana (lunes) y disminuyen a medida que se avanza en la semana para finalmente aumentar otra vez durante los días del fin de semana, alcanzando su mayor pico los días viernes. En lo que respecta a sus desviaciones estándar, estas parecen mantener un patrón diario similar en todos los días de la semana.


Gráfico No. 4:



Fuente: Empresas operadoras. Elaboración propia.

Si se analiza el patrón presentado por el máximo número de intentos de llamada, se nota claramente que en promedio el día lunes es el que presenta el pico máximo, con lo cual podríamos hablar de un proceso que se repite cada siete días.


Gráfico No. 5:



Fuente: Empresa operadora. Elaboración propia.

Durante el mes, se puede observar cómo se repite la estacionalidad semanal y diaria. De otro lado, no se nota que exista una estacionalidad de fin de mes, aunque al parecer si se registra un alto pico en las quincenas.


Gráfico No. 6:



Fuente: Empresas operadoras. Elaboración propia.

Dicho patrón se observa más claramente si tomamos la serie del número máximo de intentos de llamadas por día, mostrada en el gráfico No. 7. En dicha serie, el pico que ocurre a mitad de mes es mucho más importante.

Gráfico No. 7:




Fuente: Empresas operadoras. Elaboración propia.

c) Estacionalidad mensual:

Debido a que nuestro periodo de análisis no es una serie temporal que comprenda varios años, no es posible analizar si existe una estacionalidad mensual que se repita año a año. Sin embargo, lo que sí podemos confirmar a través del siguiente gráfico es que existe una tendencia positiva creciente posiblemente derivada del desarrollo del sector móvil, tanto a nivel de cobertura como de penetración. Asimismo, a pesar que existe este aumento sostenido en el número de intentos de llamada realizados, la volatilidad de la serie en promedios mensuales no aumenta al pasar el tiempo.

Sin embargo, evidencia encontrada en la literatura existente (Hilas et al (2006)) reporta la existencia de estacionalidad que se repite cada año en los meses donde las personas toman vacaciones de verano (agosto en el caso del documento citado), en los feriados de Navidad y dentro de las festividades de Pascua. Asimismo, se confirma la tendencia positiva, no lineal y que presenta ligeras curvaturas a lo largo del tiempo, en el caso de intentos de llamada en el servicio móvil.

Gráfico No. 8:



Fuente: Empresas operadoras. Elaboración propia.

3. Análisis Econométrico de la Serie

Una serie de tiempo es una secuencia de observaciones en el tiempo generada a partir de un proceso estocástico. Dependiendo de cómo se defina el conjunto temporal, la serie de tiempo será continua o discreta. Para el correcto análisis de la serie dos elementos son claves: en primer lugar, la modelación e identificación de los componentes de la serie (tendencial, estacional y cíclico) y, en segundo lugar, realizar una modelación que permita una buena predicción dentro y fuera de la muestra.

Mediante el análisis descriptivo realizado en la sección anterior, se ha podido constatar la naturaleza estacional de la serie, la cual se deriva de los cambios en la intensidad de actividades durante el día. Por ello, el modelo econométrico que se utilice tiene que tomar en cuenta explícitamente esta característica. De acuerdo con la literatura econométrica reciente, la estacionalidad debe ser tratada dentro de la modelación de la serie en lugar de intentar removerla antes de las estimaciones del modelo. En este sentido, modelos tales como *Seasonal Autoregressive Integrated Moving Average* (SARIMA) son ampliamente utilizados para simular flujos de tráfico que contienen componentes estacionales, series con tendencia y correlaciones de corto plazo.

Estos modelos fueron introducidos por G. Box y G. Jenkins (1976), quienes recomiendan el uso de términos autorregresivos y medias móviles estacionales para

datos trimestrales o mensuales que presenten movimientos estacionales sistemáticos. No obstante, dicha metodología también es usada para analizar datos que se registran cada hora como es el caso del tráfico móvil captado a nivel de celdas o estaciones base (Fillatre, Marakov y Vaton (2005)).

Más aún, los modelos SARIMA presentan un ajuste muy bueno en sus predicciones frente a otros modelos presentados por la literatura (Descomposiciones estacionales, métodos de suavizamiento exponencial, entre otros) para describir series de tiempo estacionales tales como el número de intentos de llamada en la red móvil. Además, estos modelos pueden ser representados de diferentes maneras y permiten ser convertidos en modelos recursivos como el filtro de Kalman.

En general, un proceso y_t considerado SARIMA $(p,d,q) \times (P,D,Q)_S$ cumple la ecuación:

$$\phi(L)\Phi(L^S)(1-L)^d(1-L^S)^D y_t = \alpha + \theta(L)\Theta(L^S)e_t$$

Donde α es una constante, L se refiere al operador de rezagos que permite simplificar de la siguiente manera $LX_t=X_{t-1}$ y $L^mX_t=X_{t-m}$, $\phi, \theta, \Phi, \Theta$ son funciones polinomiales de grados p, q, P y Q , respectivamente y e_t se comporta como un ruido blanco, es decir, una variable aleatoria de distribución normal con media cero y varianza constante. Hay que resaltar que es el componente L^S quien distingue a estos modelos de los ARIMA convencionales.

Los términos polinomiales $\phi(L)\Phi(L^S)$, los cuales multiplican el lado izquierdo de la ecuación, sirven para tomar en cuenta el componente autorregresivo de la serie; mientras que la parte de promedios móviles es recogida por los términos multiplicativos $\theta(L)\Theta(L^S)$ que se encuentran en el lado derecho. Estas funciones capturan los componentes autoregresivos y de medias móviles para la parte estacional de la serie así como para aquella parte libre de estacionalidad.

Cabe resaltar que en este tipo de procesos se asume estacionariedad débil³, intervalos de observaciones que se encuentren espaciadas igualmente en el tiempo y por lo menos 30 observaciones en la muestra. Finalmente, este tipo de modelos permiten estimar todos los parámetros recurriendo a métodos de máxima verosimilitud.


En la revisión de literatura sobre este tipo de estimaciones se encuentra un estudio realizado por Fillatre, Marakov y Vaton (2005) en el que ajustan mediante un SARIMA $(1,1,1) \times (1,1,1)_{48}$ una serie de flujo de tráfico de Internet que es medida cada media hora durante un lapso de 5 días. Asimismo, con esos mismos datos (pero agregados a nivel de día) encuentran que la serie ajusta muy bien a un modelo SARIMA $(2,1,0) \times (1,1,0)_7$.

De otro lado, Hilas et al (2006) realizan un estudio para el número total de llamadas de una red móvil usando data mensual durante un periodo de 6 años (enero 1998 a diciembre del 2003). Dicho estudio arroja que esta serie se puede modelar adecuadamente como un SARIMA $(3, 1, 0) \times (1, 1, 0)_{12}$

En nuestro caso, iniciamos el análisis con la identificación de los componentes de la serie. Para ello, obtenemos el gráfico de correlograma que se muestra a continuación. Como podemos observar, el hecho de que la autocorrelación parcial presente picos en los rezagos 1, 2, 10, 24 y 25 sugiere la existencia de un proceso autorregresivo de esos órdenes. De otra parte, la serie de la autocorrelación muestra que se existiría un proceso de medias móviles de por lo menos orden 1. Además, el patrón cíclico que presenta la autocorrelación es el que nos da un indicio de que se presenta estacionalidad en la parte autorregresiva de la ecuación que no podrá ser capturado a través de los componentes de un ARIMA tradicional.

³. Un proceso estocástico y_t es estacionario en sentido débil si se cumple que:
 $E(y_t) = \mu \quad \forall t, \text{ var}(y_t) = \sigma^2$ y $\text{cov}(y_i, y_j) = \text{cov}(y_{i+k}, y_{j+k}) = \gamma(i-j) = \gamma(j-i), \forall i \neq j$ siendo μ y σ sendos parámetros y siendo k un número entero.

Gráfico No. 9:



Fuente: Empresas operadoras. Elaboración propia.

Otro tema importante es asegurarnos de que la serie es estacionaria o, si no lo es, obtener las primeras diferencias de tal manera que se convierta en integrada de orden cero (I(0)) pues, como se mencionó anteriormente, para estimar mediante esta metodología se debe de cumplir dicho requisito. Por tal razón, se utilizó una prueba de raíz unitaria tipo Elliott-Rothenberg y Stock GLS⁴ aplicado a la serie en niveles donde la hipótesis nula es que la serie presenta una raíz unitaria. Los resultados se presentan a continuación y como se puede observar, no se puede rechazar la hipótesis nula con un nivel de 99% de confianza. Luego, tomando en cuenta dicho resultado, se estima la serie en primeras diferencias, la cual si rechaza la hipótesis de raíz unitaria al 99% de confianza.

**Cuadro No. 1:
Prueba de raíz unitaria**

Prueba Elliot Rothenberg Stock DF-GLS	
T estadístico	0.024126
1%	-2.565459
Valores Críticos 5%	-1.940892
10%	-1.616654

Fuente: Empresas operadoras. Elaboración propia.

⁴. Elliott-Rothenberg y Stock (1996).

Por otro lado, debemos verificar la existencia de problemas de heterocedasticidad y si es que se puede modelar de alguna forma la varianza, para lo cual necesitaríamos de los modelos GARCH (n,m). Dichos modelos permiten estimar además de la especificación de la serie y_t , la correspondiente a la varianza condicional de y_t . Así, esta última dependerá de los rezagos de los residuos de la primera especificación así como de la misma varianza condicional rezagada. La parte que depende de los rezagos de los residuos de la ecuación de y_t se le conoce como un proceso ARCH de orden n, si es que depende de los n primeros rezagos. Si, además, la varianza condicional depende de sus propios rezagos se dirá que existe un proceso GARCH de orden m, siendo este el orden del polinomio que describe el número de rezagos de la varianza condicional. Juntos forman un proceso GARCH (n, m).

Finalmente, se estima un modelo como el descrito y en el cuadro que se presenta a continuación se muestran los resultados. Dicha estimación contó con los mejores criterios de bondad de ajuste, medidos por el R cuadrado y R cuadrado ajustado, AIC y BIC. Como se puede observar, se hace una corrección SAR por la estacionalidad que sucede a cada hora del día (es decir cada 24 periodos o 1 día) y para la estacionalidad recurrente cada 168 periodos (cada semana). Dentro de dichos periodos estacionales, a su vez, se encuentran procesos autorregresivos de orden 1,6, 16 y 24. Asimismo, se ajustó un proceso GARCH (4,2) para el error de estimación. Cabe resaltar que cada regresor utilizado en el modelo resultó significativo. Así, se cuenta con una especificación tipo SARIMA (24,1,1) x (7,0,0)₂₄⁵ con residuos GARCH (4,2) con lo que se especifica un proceso tal que:

$$(1 - \phi_1 L^1 - \phi_6 L^6 - \phi_{16} L^{16} - \phi_{24} L^{24})(1 - \Phi_{24} L^{1*24} - \Phi_{168} L^{7*24})(1 - L)y_t = (1 + \theta_1 L)\varepsilon_t$$

$$\sigma_t^2 = \alpha + \sum_{j=1}^4 \beta_j \sigma_{t-j}^2 + \sum_{i=1}^2 \gamma_i \varepsilon_{t-i}^2$$

⁵. En el proceso AR, los rezagos relevantes fueron 1, 6, 16 y 24 y en el proceso SAR, el 1 y 7.

Cuadro No. 2:
Estimación de Modelo SARIMA para los Intentos de Llamada

Variable dependiente: Primera diferencia del total de intentos de llamada por hora.
Muestra: 4461 observaciones.

Especificación SARIMA	Coefficientes
AR(1)	0.9442*** (0.0064)
AR(6)	-0.0460*** (0.0064)
AR(16)	-0.0512*** (0.0051)
AR(24)	0.0401*** (0.0045)
SAR(24)	0.3707*** (0.0077)
SAR(168)	0.6114*** (0.0080)
MA(1)	-0.9975*** (0.0015)

Especificación GARCH	Coefficientes
Ecuación de varianza	
Constante	2310.772*** (70.5647)
Residuo (-1) ²	0.3179*** (0.0190)
Residuo (-2) ²	0.5338*** (0.0247)
Residuo (-3) ²	0.5104*** (0.0258)
Residuo (-4) ²	0.2028*** (0.0151)
GARCH (-1)	-1.0022*** (0.0188)
GARCH (-2)	-0.9375*** (0.0281)

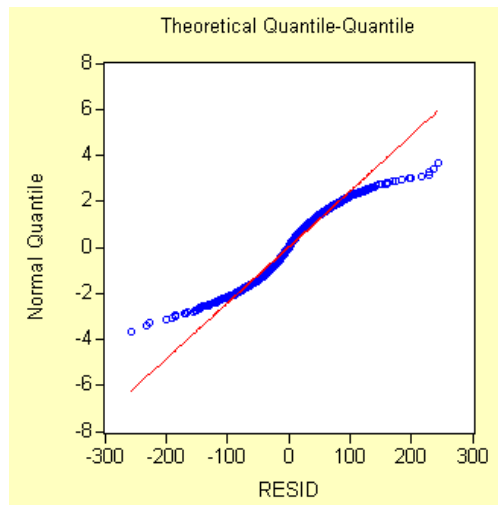
Fuente: Empresas operadoras. Elaboración propia.

Nota: Los errores estándar se encuentran en paréntesis, los tres asteriscos indican que dicha estimación se encuentra al 95% de confianza.

Luego de la estimación, se desea conocer también si los residuos son procesos ruido blanco y si se encuentran distribuidos de forma similar a una variable aleatoria normal. Para ello, se realizaron pruebas en los residuos de la estimación que se presentan a continuación.

En primer lugar, se usó la prueba cuantil – cuantil para conocer qué grado de similitud tenía la distribución de los residuos con la distribución normal. Mientras los puntos azules en el gráfico siguiente se encuentren encima de la recta roja, la distribución de la serie analizada se parecerá más a una distribución normal. Como se observa, el ajuste no es perfecto, pero sigue siendo bastante buena.

Gráfico No. 11:
Prueba Cuantil – Cuantil para los Errores de Estimación



Fuente: Empresas operadoras. Elaboración propia.

Un segundo paso consistió en analizar el correlograma de los residuos de la regresión, los cuales se muestran siempre dentro de las bandas especificadas, es decir, que estos no se encuentran correlacionados entre sí en el tiempo.

Gráfico No. 12:
Correlograma de los Residuos de la Regresión

Autocorrelación	Autocorr. Parcial	AC	PAC	Q-Stat	Prob	
		1	0.063	0.063	17.703	
		2	0.014	0.010	18.614	
		3	0.021	0.020	20.631	
		4	-0.025	-0.028	23.399	
		5	-0.025	-0.022	26.216	
		6	-0.016	-0.013	27.374	
		7	-0.026	-0.023	30.494	
		8	-0.059	-0.056	46.105	0.000
		9	0.024	0.031	48.632	0.000
		10	0.044	0.042	57.103	0.000
		11	0.023	0.018	59.499	0.000
		12	0.046	0.038	69.139	0.000
		13	0.049	0.041	80.004	0.000
		14	0.028	0.023	83.613	0.000
		15	0.011	0.006	84.107	0.000
		16	-0.003	-0.004	84.138	0.000
		17	-0.019	-0.011	85.759	0.000
		18	-0.031	-0.021	90.190	0.000
		19	-0.020	-0.012	91.899	0.000
		20	-0.044	-0.037	100.52	0.000
		21	-0.011	-0.003	101.04	0.000
		22	0.005	0.003	101.18	0.000
		23	0.049	0.043	111.78	0.000
		24	-0.020	-0.035	113.52	0.000
		25	0.063	0.057	131.61	0.000
		26	0.019	0.003	133.21	0.000
		27	0.027	0.025	136.39	0.000
		28	0.005	-0.003	136.48	0.000

Fuente: Empresas operadoras. Elaboración propia.

Finalmente, realizamos una prueba ARCH-LM (prueba de multiplicador de Lagrange para detectar heterocedasticidad condicional en los residuos) que nos da información acerca si es que con la estimación GARCH realizada no se ha tomado en cuenta todos los regresores necesarios para especificar de forma correcta la ecuación de varianza condicional. La hipótesis nula de esta prueba consiste en que no existe un componente de heterocedasticidad condicional más en los residuos. Como se puede comprobar en el cuadro No. 3, no se puede rechazar la hipótesis nula, es decir, los residuos se encuentran bien comportados.

**Cuadro No. 3:
Prueba ARCH-LM**

Prueba ARCH - LM	
F estadístico	0.752223
Prob. F(3, 4454)	0.520934

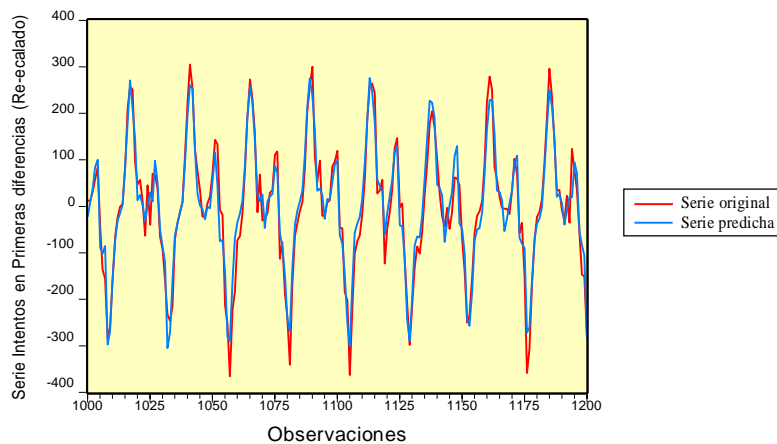
Fuente: Empresas operadoras. Elaboración propia.

4. Predicción y ajuste:

Una vez terminado el proceso de estimación, es necesario corroborar si es que este proceso nos permite realizar predicciones que, comparadas con los datos reales con los que se cuenta, se reproduce la verdadera secuencia.

Por tanto, se realizó una predicción de acuerdo al modelo especificado anteriormente, la cual se muestra en el gráfico No. 13. En dicho gráfico se puede ver con claridad el buen ajuste del modelo pues permite replicar el proceso generador de la serie con mucha precisión. Hay que mencionar que en el gráfico sólo se ha tomado un intervalo corto de los datos para que se pueda apreciar con claridad la calidad del ajuste de la predicción.

Gráfico No. 13:
Ajuste del modelo SARIMA a serie de Intentos de Llamada



Fuente: Empresas operadoras. Elaboración propia.

Finalmente, se debe notar que la predicción, como sucede también en el caso de la predicción del máximo número de intentos al día, falla fundamentalmente en pronosticar los picos que presenta la serie, es decir, cuando existe una cantidad extraordinaria de intentos de llamada por hora o cuándo esta cantidad es mínima. Ello se presenta como un efecto esperable dado que la estimación permite capturar patrones promedio y no los eventos atípicos que pueda presentar la muestra.

5. Conclusiones:

En el presente documento, se ha intentado modelar la serie del total de intentos de llamada por hora realizados por los usuarios de telefonía móvil. Dicha serie tiene como característica principal la importante presencia de un componente estacional que se deriva de las actividades usuales de las personas durante el día, la semana o el mes.

Esta característica de estacionalidad fue capturada en la modelación de la serie mediante estimaciones SARIMA, en los cuales se utiliza la multiplicación de polinomios para tomar en cuenta este fenómeno. Estos modelos son recomendados por la literatura existente para aproximarnos a series de flujos de tráfico como la demanda por servicios de Internet, celular o teléfono fijo.

La modelación de dicho proceso es de suma importancia tanto para los organismos reguladores como para las empresas operadoras pues de ello dependen decisiones

sobre tarifas, normativa regulatoria, así como estrategias comerciales y dimensionamiento de la red.

En ese sentido, el presente trabajo ha buscado proporcionar una visión más precisa acerca del patrón de demanda de los usuarios de servicios móviles. Un ejercicio posterior debería constatar si es que la especificación utilizada para replicar el patrón de llamadas puede variar en el tiempo. Además, es importante realizar un análisis complementario sobre los determinantes adicionales de este patrón en función de variables adicionales que capturen sobre todo el nivel socioeconómico de los usuarios.

Referencias

BOX, G y G. Jenkins (1976) *Time Series Analysis, Forecasting, and Control*, Holden Day, San Francisco.

ENDERS, W. (2005) *Applied Econometric Times Series*. Wiley Series in Probability and Statistics. 2nd. Edition.

ELLIOTT, G., Rothenberg, T.J. y J.H. Stock (1996) *Efficient Tests for an Autoregressive Unit Root*, *Econometrica*, 64, 813–836

FILLATRE, L., D.Marakov y S.Vaton (2005), *Forecasting Seasonal Traffic Flows*, EuroNGI Workshop on QoS and Traffic Control, Paris, 7-9.