



UNIVERSIDAD NACIONAL AUTÓNOMA  
DE MÉXICO

---

---

FACULTAD DE CIENCIAS

“PRONÓSTICO DE DEMANDA DE EFECTIVO  
EN SUCURSALES”

T E S I S

QUE PARA OBTENER EL TÍTULO DE

A C T U A R I O

PRESENTA:

PARIS ADOLFO VILORIA BERNAL

DIRECTOR DE TESIS:

M. EN A.P. MARÍA DEL PILAR ALONSO REYES



2008



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

A Sofia, mi madre

## Agradecimientos

Quiero agradecer a las mujeres que siempre me han rodeado ya que ellas han sido mi mayor motivación.

Mi madre la mujer más fuerte e inteligente que conozco.

Mi abuela Carmela, quien es como mi segunda madre.

Mi hermana Roxana, la cual me ha apoyado incondicionalmente.

Mi tía Mau, por mostrarme siempre su cariño incondicional

Priscilla, la mujer a la cual amaré hasta el último de mis días, gracias por enseñarme a hacer las cosas bien.

Gracias a todos mis familiares y amigos cercanos; en especial a Luis, Aram, José y Mario.

# Contenido

Introducción	1
<b>Capítulo 1 Objetivo</b>	<b>3</b>
<b>Capítulo 2 Modelos ARIMA</b>	<b>4</b>
2.1 Operadores y Polinomios de Retraso	5
2.2 Procesos Estacionarios	7
2.3 Modelos Autorregresivos (AR)	8
2.3.1 MODELOS AR(p)	10
2.4 Modelos de Promedios Móviles (MA)	10
2.4.1 MODELOS MA(q)	11
2.5 Modelos ARMA	12
2.5.1 MODELOS ARMA (p, q)	12
2.6 Modelos ARIMA	13
<b>Capitulo 3 Desarrollo</b>	<b>14</b>
3.1 Tratamiento de los datos	15
3.1.1 Análisis gráfico	15
3.1.2 Estabilización de la Varianza	18
3.1.3 Estabilización del nivel de la serie	18
3.2 Identificación del modelo	22
3.2.1 Supuestos a verificar	23
3.3. Obtención del modelo	26
3.5 Pronóstico	31
<b>Conclusiones</b>	<b>32</b>
<b>Anexos</b>	<b>33</b>
Modelo 1	33
Modelo 2	36
Modelo 3	39
Modelo 4	42
Modelo 5	43
Modelo 6	48
<b>Referencias</b>	<b>52</b>

## Introducción

El área de logística monetaria de un banco es la encargada de planear la distribución a nivel nacional del efectivo de una forma eficiente, oportuna y óptima.

Podría pensarse que los bancos tienen recursos ilimitados de dicho insumo en sus bóvedas, pero no es así, el flujo de efectivo empieza en Banco de México (Banxico), que es la entidad que regula el sistema bancario de México. Dicha institución emite la circular 2026 (Disposiciones de Operaciones de Caja)<sup>1</sup>, en donde se regula las disposiciones relativas al almacenamiento, abastecimiento, canje, entrega y retiro de billetes y monedas metálicas.

Por lo que la logística monetaria debe regirse por dicha circular y hacer cumplir a nivel nacional todos los estándares dictados por Banxico para operar tanto en sucursales como las políticas monetarias del banco.

La planeación del flujo de efectivo del banco se hace con base en estimaciones de los requerimientos de clientes, de los cajeros automáticos (o ATM por sus siglas en inglés Automatic Teller Machine), y sucursales. El área de pronóstico de efectivo es la encargada de hacer dichas estimaciones para posteriormente entregar las cifras a los encargados de planeación de efectivo para la caja, quienes recopilan la información y comparan con el saldo físico con el que se cuenta en las diferentes bóvedas a nivel nacional del banco.

Las bóvedas están a cargo de empresas contratadas por el banco como pueden ser SEPSA, COMETRA, TAMEME, CORPO PROFIN, etc. A estas empresas se les denomina empresas de proceso (EP), a ellas es a quienes se les da la orden,

---

<sup>1</sup> Véase la página de Banco de México  
[http://www.banxico.org.mx/billetesymonedas/disposiciones/circulares/circular2026/2026\\_texto.html](http://www.banxico.org.mx/billetesymonedas/disposiciones/circulares/circular2026/2026_texto.html)

con base en los requerimientos, de solicitar el retiro, depósito o traslado de una región a otra del efectivo; cuidando cubrir la demanda para evitar desabasto, no generar improductivo por el costo de oportunidad y siempre al menor costo.

Las empresas de traslado de valores (ETV), quienes por lo regular son las mismas empresas que procesan el efectivo, se encargan de distribuir el efectivo a las sucursales, clientes y surtir los ATM, a nivel nacional.

Posteriormente las mismas ETV, son las encargadas de recolectar el efectivo sobrante tanto de la operación de las sucursales como de los ATM, además de los depósitos de los clientes corporativos. Cuando se tiene nuevamente el efectivo en las EP se vuelve a contar, se verifica y se clasifica dando inicio nuevamente al flujo de efectivo del banco donde se analizan la demanda y la existencia para saber si se coloca o se conserva el dinero para optimizar los recursos.

El presente trabajo se centrará en el pronóstico de efectivo de las sucursales con el fin de obtener el modelo que minimice el riesgo de un desabasto evitando también los excedentes que provocan costos de oportunidad para el banco.

# 1 Objetivo

El principal insumo para la operación de las sucursales es el efectivo; el cual sirve no sólo para ser pagado en ventanillas, sino también para surtir a los ATM ubicados dentro de las sucursales.

Derivado de lo anterior, es por tanto importante contar con un modelo adecuado que estime la demanda de efectivo de las sucursales en el corto plazo para poder planear retiros y depósitos de Banxico, y en caso de ser necesario trasladarlo de otra región, con el fin de cumplir con el objetivo de logística monetaria que es “Suministrar el efectivo a nivel nacional de forma eficiente y oportuna al menor costo”.

Para lograr lo anterior se construirá un modelo ARIMA a partir de los datos mensuales de las dotaciones de efectivo a sucursales a nivel nacional (DotSuc), observados de enero de 2003 a agosto de 2006, con el fin de obtener un pronóstico de 4 meses de demanda de efectivo.

Para alcanzar el objetivo, se utilizará la estrategia de construcción de modelos para series de tiempo desarrollada por Box & Jenkins (B&J), siguiendo las recomendaciones del libro de Victor Manuel Guerrero Guzmán (2003), utilizando los paquetes Econometric Views V.5 (EViews) y Regression Analysis of Time Series V.6.1 (RATS).



## 2 Modelos ARIMA

Como se comentó anteriormente, la metodología a seguir será mediante el enfoque del análisis de series de tiempo sugerido por Box y Jenkins el cual apareció dentro de su libro *Time Series Análisis: Forecasting and Control* en 1970. Popularmente conocida como metodología de Box-Jenkins (B&J), pero técnicamente conocida como metodología ARIMA. El énfasis de este método no está en la construcción de modelos uniecuacionales o de ecuaciones simultáneas sino en el análisis de las propiedades probabilísticas o estocásticas de las series de tiempo económicas por sí mismas. A diferencia de los modelos de regresión, en los cuales  $Y_t$  está explicada por las variables regresoras  $X_1, X_2, X_3, \dots, X_k$ , en los modelos de series de tiempo del tipo B&J,  $Y_t$  puede ser explicada por valores pasados o rezagados de sí misma, y por los términos estocásticos de error.

La estrategia de construcción de modelos consta de las siguientes etapas:

1. Identificación del modelo (dentro de una clase general de modelos y de acuerdo con lo que los datos indiquen), apoyados con la FAC y FACP de la serie.
2. Estimación de los parámetros implícitos en el modelo (para lo cual se debe usar la técnica más eficiente que se conozca).
3. Verificación de supuestos (a fin de que los resultados que se deriven del modelo puedan considerarse válidos).
4. Uso del modelo (para los fines que motivaron su construcción entre ellos el pronóstico).

## 2.1 Operadores y Polinomios de Retraso

En prácticamente todo análisis estadístico, excepto en el análisis de series de tiempo, se supone que las observaciones que se tienen provienen de variables aleatorias independientes, de forma tal que con el conocimiento de las funciones de densidad individuales, es posible obtener fácilmente la función de densidad conjunta. En contraste, en el caso de las series de tiempo se supone que existe toda una estructura de correlación entre las observaciones; por consiguiente, no es posible obtener la función de densidad conjunta de manera tan directa y deberá utilizarse alguna otra forma para caracterizar las variables aleatorias que intervienen. Con este objetivo en mente y para facilitar la exposición subsecuente, es conveniente presentar algunos operadores y polinomios de uso frecuente en el análisis de series de tiempo.

El primer operador, el cual se mencionará, se llama operador de retraso, que se denota por la letra B (del inglés backward), y se define de la siguiente forma:

$$BZ_t = Z_{t-1} \text{ para toda } t$$

Por la aplicación sucesiva del operador B se obtiene:

$$B^2 Z_t = B(BZ_t) = Z_{t-2}$$

y en general, la expresión a la que se llega es:

$$B^k Z_t = Z_{t-k} \text{ para } k \in \mathbb{N} \text{ y toda } t$$

Otro operador de uso frecuente y que está íntimamente ligado con B es el operador diferencia  $\nabla$ . Este operador se utiliza para expresar relaciones del tipo

$Y_t = Z_t - Z_{t-1}$ , donde, si  $Z_t$  es una variable de saldo, entonces  $Y_t$  será la variable de flujo correspondiente; es decir, si se define a  $\nabla$  mediante:

$$\nabla Z_t = Z_t - Z_{t-1} \text{ para toda } t$$

se tiene que  $Y_t$  puede escribirse como  $Y_t = \nabla Z_t$ .

La relación que liga a  $\nabla$  con  $B$  es la siguiente:

$$\nabla = 1 - B \quad \text{o sea} \quad \nabla Z_t = (1 - B)Z_t$$

de esta manera, así como se obtuvo una expresión general para  $B^k$  mediante la aplicación sucesiva del operador  $B$ , así también podría obtenerse la siguiente forma general para  $\nabla^k$ :

$$\nabla^k Z_t = \sum_{j=0}^k \frac{k!}{j!(k-j)!} (-1)^j Z_{t-j} \text{ para } k \in \mathbb{N} \text{ y toda } t$$

Como se puede apreciar  $\nabla^k$  es en realidad un binomio elevado a la  $k$ -ésima potencia, o sea  $\nabla^k Z_t = (1 - B)^k Z_t$

El uso de polinomios de retraso es importante en el estudio de series de tiempo porque permiten expresar, de una manera concisa y simple, algunos de los modelos que han probado ser de mayor utilidad en la práctica para representar fenómenos reales. Cabe mencionar que dentro de estos modelos se encuentran los modelos autorregresivos y los de promedios móviles los cuales se detallarán más adelante.

## 2.2 Procesos Estacionarios

El concepto de estacionariedad es de suma importancia para el análisis de series de tiempo, como se mencionó, para caracterizar completamente un proceso estocástico es necesario conocer la función de densidad conjunta de sus variables aleatorias; sin embargo en la práctica no es realista pensar que esto puede lograrse con una serie de tiempo.

En términos generales, se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende solamente de la distancia o rezago entre estos dos periodos de tiempo y no del tiempo en el cual se ha calculado la covarianza.

Se habla de un proceso puramente aleatorio (o de ruido blanco) si tiene una media igual a cero, una varianza constante  $\sigma^2$  y no está serialmente correlacionada.

El hecho de que en la mayor parte de las series de tiempo con las que uno trabaja en la práctica no sean estacionarias, no es tan grave como parece a primera vista, ya que existen formas para solucionar este problema y convertir en estacionarias series que originalmente no lo son. En muchos casos prácticos, la no estacionariedad de la serie es homogénea, lo cual significa que es únicamente el nivel de la serie el que se ve afectado por la no estacionariedad, debido a que existe alguna tendencia polinomial adaptiva. En estos casos es posible eliminar la tendencia y, por tanto, volver la serie estacionaria mediante la aplicación del operador  $\nabla$  un número apropiado de veces.

El propósito de tomar diferencias es volver estacionario el nivel de una serie, pero debe recordarse que si se toman diferencias de series que ya son estacionarias, éstas seguirán siendo estacionarias, lo cual significa que fácilmente podría

sobrediferenciarse una serie al tratar de volverla estacionaria. El hecho de sobrediferenciar una serie acarrea problemas en la identificación de algún modelo para representarla, y se incrementa la varianza de la serie.

## 2.3 Modelos Autorregresivos (AR)

Téngase la ecuación:

$$A(B)Z_t = \text{constante}$$

donde  $A(B)$  representa un polinomio de retraso. Una generalización de este tipo de ecuaciones consiste en introducir una variable aleatoria en el lado derecho, de tal manera que se tenga:

$$A(B)Z_t = \text{constante} + a_t$$

en donde, por simplicidad, se supone que  $\{a_t\}$  es un proceso de ruido blanco.

Ecuaciones en diferencia<sup>1</sup> de este tipo permiten representar los procesos autorregresivos de la siguiente forma:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = \text{constante} + a_t$$

en donde la constante es igual a  $(1 - \phi_1 - \phi_2 - \dots - \phi_p)\mu$ , en caso de que el proceso  $Z_t$  tenga un nivel medio constante dado por  $E(Z_t) = \mu$  para toda  $t$ ; de esta forma, la ecuación se convierte en:

---

<sup>1</sup> Véase Análisis Estadístico de Series de Tiempo Económicas, Guerrero Victor Capítulo 2 Elementos de Ecuaciones en Diferencia

$$\phi(B)\tilde{Z}_t = a_t \quad \text{con} \quad \tilde{Z}_t = Z_t - \mu$$

El término autorregresivo (AR) que se le da al proceso representado por la ecuación anterior, se refiere al hecho de que también puede expresarse como:

$$Z_t = (1 - \phi_1 - \phi_2 - \dots - \phi_p)\mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t$$

la cual es básicamente una ecuación de regresión lineal, con la característica especial de que el valor de la variable dependiente  $Z$  en el periodo  $t$  depende, no de los valores de un cierto conjunto de variables independientes, como sucede en el modelo de regresión, sino de sus propios valores, observados en periodos anteriores a  $t$  y ponderados de acuerdo con los coeficientes autorregresivos  $\phi_1, \phi_2, \dots, \phi_p$ .

Al referirse a ecuaciones en diferencia en las que interviene algún elemento aleatorio, no es estrictamente válido hablar de convergencia aun cuando éstas ocurran alrededor del punto de equilibrio. Por tanto es necesario utilizar el concepto de equilibrio estocástico, mejor conocido como estacionariedad, que ya fue presentado anteriormente. Es decir, mientras que en un proceso determinista se habla de equilibrio, cuando se tiene un proceso estocástico se habla de estacionariedad; de esta manera, un proceso AR será estacionario o no estacionario, dependiendo de los valores que tomen las raíces de la ecuación característica:

$$\phi_1(x) = 0$$

la cual rige el comportamiento del proceso autorregresivo y será estacionario si y sólo si las raíces de esta ecuación se encuentran fuera del círculo unitario (en el plano complejo).

### 2.3.1 MODELOS AR(p)

Como caso general de un proceso autorregresivo, se procede a considerar el proceso AR(p) que se describe mediante la siguiente ecuación:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t \quad \text{en donde} \quad \tilde{Z}_t = Z_t - \mu$$

Esta ecuación es básicamente una ecuación de regresión lineal donde el valor de  $\tilde{Z}_t$  en el periodo t depende de sus propios valores observados en periodos anteriores.

Un proceso AR(p) será estacionario si y sólo si las raíces de la ecuación característica

$$1 - \phi_1 x - \phi_2 x^2 - \dots - \phi_p x^p = 0$$

se encuentran fuera del círculo unitario.

### 2.4 Modelos de Promedios Móviles (MA)

La idea básica de estos modelos se basa en representar un proceso estocástico  $\{\tilde{Z}_t\}$ , cuyos valores pueden ser dependientes unos de otros, como una suma finita ponderada de choques aleatorios independientes  $\{a_t\}$ , o sea:

$$\tilde{Z}_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t = \theta(B) a_t$$

en donde  $\{\tilde{Z}_t\}$  representa las desviaciones de  $\{Z_t\}$  respecto a su nivel medio  $\mu$  y  $\theta_1, \theta_2, \dots, \theta_q$  que son las ponderaciones (parámetros de promedios móviles) asociados con los choques aleatorios en los periodos  $t-1, t-2, \dots, t-q$ , respectivamente.

### 2.4.1 MODELOS MA(q)

En general, un proceso estocástico se dirá que sigue un esquema de promedios móviles de orden  $q \geq 1$  si se le puede representar mediante

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

con  $\tilde{Z}_t = Z_t - \mu$ , en donde  $\mu$  es el nivel del proceso,  $\theta_1, \theta_2, \dots, \theta_q$  son los parámetros de promedios móviles y  $\{a_t\}$  es un proceso de ruido blanco con media cero y varianza constante  $\sigma_a^2$ . Cabe señalar que todo proceso MA es estacionario, y en particular ni la media, ni la varianza, ni las covarianzas del proceso MA(q), dependen del tiempo.

Para el caso de los modelos MA debe verificarse que el polinomio de promedios móviles sea invertible, cumpliendo que las raíces de su ecuación característica caigan fuera del círculo unitario.



## 2.5 Modelos ARMA

Una generalización de los modelos AR y MA previamente descritos, consiste en combinar ambas clases de modelos para obtener lo que se conoce como modelos *autorregresivos y de promedios móviles* (ARMA). El proceso ARMA (p,q) se representa mediante:

$$\phi(B)\tilde{Z}_t = \theta(B)a_t$$

en donde  $\phi(B)$  y  $\theta(B)$  son polinomios de retraso de orden p y q respectivamente,  $\{a_t\}$  es un proceso de ruido blanco y  $\tilde{Z}_t$  representa a su nivel  $\mu$ .

### 2.5.1 MODELOS ARMA (p, q)

El caso general de un proceso ARMA (p, q) se representa mediante

$$\phi(B)\tilde{Z}_t = \theta(B)a_t$$

en donde  $\phi(B)$  y  $\theta(B)$  son polinomios de retraso de orden p y q respectivamente, es decir

$$\tilde{Z}_t - \phi_1\tilde{Z}_{t-1} - \dots - \phi_p\tilde{Z}_{t-p} = a_t - \theta_1a_{t-1} - \dots - \theta_qa_{t-q}$$

## 2.6 Modelos ARIMA

Los modelos *autorregresivos e integrados de promedios móviles* (ARIMA) pueden ser vistos como una generalización de los modelos ARMA. Esto permite gran flexibilidad de representación a los modelos ARMA, puesto que en realidad lo que se hace al aplicar el operador diferencia  $\nabla^d$  es eliminar una posible tendencia polinomial de orden  $d$ , presente en la serie que se analice. Visto desde otro ángulo, si el proceso original  $\{\tilde{Z}_t\}$  adolece de no estacionariedad causada por una tendencia polinomial no determinista (a la cual se le denomina no estacionariedad homogénea) es posible construir el proceso estacionario  $\{W_t\}$ , en donde

$$W_t = \nabla^d \tilde{Z}_t \quad \text{para toda } t$$

para esta nueva serie ya podría ser posible obtener un modelo ARMA:  $\phi(B)W_t = \theta(B)a_t$ , lo cual sería equivalente a considerar el modelo ARIMA

$$\phi(B)\nabla^d \tilde{Z}_t = \theta(B)a_t, \quad d \geq 1$$

para  $\{\tilde{Z}_t\}$ , en donde  $\{a_t\}$  es un proceso de ruido blanco.

### 3 Desarrollo

Siguiendo la metodología de Box & Jenkins para la construcción del modelo se procedió de la siguiente forma:

1. Primero se realizó el análisis visual de la serie, graficando las observaciones de demanda contra el tiempo y con ayuda del paquete EViews versión 5.0 se realizaron gráficas de caja y brazos, esto con el fin de identificar si existía tendencia y estacionalidad. Así mismo se realizaron los análisis correspondientes para hacer la serie estacionaria a través de la transformación potencia y diferencias regulares y estacionales en el paquete RATS.
2. Una vez que se hizo estacionaria la serie conforme a la transformación potencia y aplicando las diferencias correspondientes, se procedió a asociar la Función de Auto Correlación (FAC) y la Función de Auto Correlación Parcial (FACP) a un posible modelo ARIMA.
3. Una vez que se identificó un modelo se procedió a la estimación de los parámetros.
4. Se llevó a cabo la verificación de los supuestos repitiendo los pasos anteriores hasta que se obtuvo un modelo satisfactorio.
5. Se realizó el pronóstico.
6. Con base en los resultados se sacaron las conclusiones del trabajo.

### 3.1 Tratamiento de los datos

#### Datos


<b>DOTACIÓN DE EFECTIVO A SUCURSALES *</b>				
	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>
ENE	19,041.70	17,348.53	13,846.29	14,267.37
FEB	16,194.75	15,741.09	12,619.97	13,570.85
MAR	18,385.81	18,388.79	14,874.74	15,755.95
ABR	18,049.34	17,837.80	14,307.64	14,439.03
MAY	17,965.33	17,686.84	16,332.12	17,440.32
JUN	17,547.77	17,036.90	14,525.76	16,662.33
JUL	17,638.26	16,920.24	14,456.31	15,785.62
AGO	16,996.75	17,647.40	15,090.10	15,597.66
SEP	17,158.03	15,726.90	14,048.12	15,751.90
OCT	18,091.89	16,076.04	14,697.34	
NOV	16,787.55	16,628.77	14,590.25	
DIC	25,313.32	21,784.57	21,507.63	

#### 3.1.1 Análisis gráfico

Se presentan los datos mensuales de dotación de efectivo a sucursales observados de enero de 2003 a septiembre de 2006

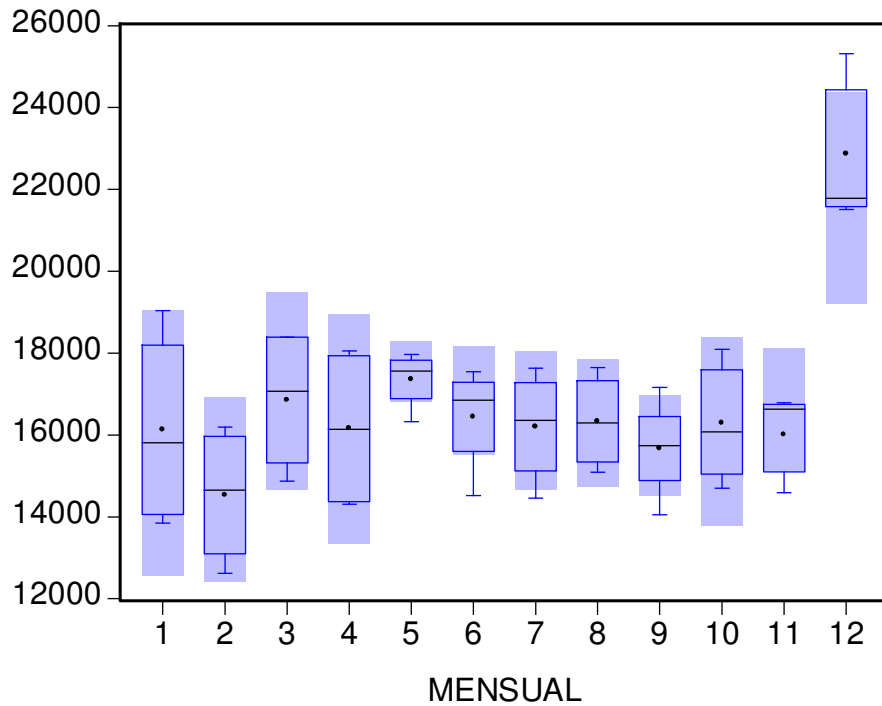
\* Los datos fueron modificados previamente mediante una transformación geométrica para no evidenciar los datos verídicos ya que es información confidencial.

### Dotación de Efectivo a Sucursales (DotSuc)




Se observa un comportamiento estacional anual a lo largo de la historia, con un nivel estacionario y varianza constante.

### Gráfica de Caja y Brazos serie DotSuc



Con un análisis gráfico de caja y brazos se comprueba la estacionalidad de la serie, siendo diciembre el mes que presenta mayor salida de efectivo.

**Gráfica de Caja y Brazos serie DotSuc**



Haciendo el análisis gráfico de caja y brazos de forma anual se observa una tendencia decreciente entre los años de 2003 y 2005, esto se dio por el cambio de política que se presentó en el año 2005 del banco, donde se incrementó el límite permitido en las bóvedas de las sucursales; lo que hizo que las Unidades de Negocio (sucursales) solicitaran menor cantidad de efectivo.

El año 2006 presenta un aumento en la demanda explicándose por el incremento en el número de sucursales a nivel nacional.

### 3.1.2 Estabilización de la Varianza

Se utiliza el método sugerido por Guerrero (1993) para seleccionar la transformación estabilizadora de varianza, para lo cual se crean grupos de 12 observaciones de los cuales se obtuvo su media y su desviación estándar calculándose posteriormente el coeficiente de variación. La decisión a tomar es considerar la transformación que observe menor coeficiente de variación sin embargo, en la práctica, generalmente se elige aquella que pudiera tener una interpretación práctica.

Grupo	Potencia ( $\lambda$ )						
	-1	-0.5	0	0.5	1	1.5	2
I	0.000007	0.000951	0.128588	17.378227	2348.61233	317407.52	42896621.3
II	0.000005	0.000705	0.092978	12.265452	1618.0366	213448.508	28157747.1
III	0.00001	0.001189	0.145937	17.918372	2200.04116	270123.935	33166170.5
Coeficiente de Variación	0.297218	0.255097	0.220402	0.196764	<b>0.187843</b>	0.194949	0.215728

Se obtiene que la transformación de  $\lambda = 1.0$  es la que tiene el mínimo coeficiente de variación, por lo que se trabajará con la serie en su nivel.

### 3.1.3 Estabilización del nivel de la serie


Ya que se determinó la transformación potencia para estabilizar la varianza se procedió a nivelar de la serie mediante la aplicación de diferencias regulares y estacionales, esto con el fin de poder trabajar la serie en su forma estacionaria.

Debido a que en la práctica es común suponer que la distribución asociada con las series de tiempo es la normal, se sigue que es suficiente conocer la media y la función de autocovarianza para caracterizar completamente una serie estacionaria. Sin embargo, para evitar la influencia de las unidades de medida, es preferible trabajar con la función de autocorrelación. La función de autocorrelación sirve para especificar, junto con la media y la desviación estándar, un proceso estocástico estacionario

Como lo sugiere Guerrero (2003), se observa la FAC para determinar si existe un decaimiento rápido de las autocorrelaciones que es indicativo de una serie estacionaria.

Al graficar la FAC se observa que la serie DotSuc no presenta un decaimiento rápido a cero por lo que se hace necesario diferencias regulares para cancelar la tendencia que se observó anteriormente. Además se nota un brinco considerable en las observaciones 12 y 24, por lo que se deben hacer diferenciaciones estacionales.

**FAC DotSuc**





Otra herramienta es revisar la varianza de las series que se les aplicó el operador diferencia ya que al tomar las diferencias de la serie, ésta se altera de tal forma que decrece hasta que la serie es estacionaria para luego crecer con la sobrediferenciación (Kendall y Stuart, 1968).


**Desviaciones Estándar Muestrales**

$S(0, 0) = 2332.12919$	$S(1, 0) = 3049.36752$	$S(2, 0) = 5238.75259$
$S(0, 1) = 1601.75918$	$S(1, 1) = 1133.52422$	$S(2, 1) = 1829.40661$
$S(0, 2) = 3037.03381$	$S(1, 2) = 1812.54383$	$S(2, 2) = 3027.28426$

**Mínima 1133.5242**


De la simple observación de la FAC de la serie DotSuc se concluye que la serie no es estacionaria, por lo que se procede al análisis gráfico de las diferenciaciones; apoyados con el método de la mínima varianza.

**FAC 1 Diferencia Regular, 0 Diferencia Estacional ( $\nabla$ DotSuc)**




Realizando una diferencia regular se siguen presentando los brincos en las observaciones 12 y 24, por lo que se pasará a realizar una diferencia estacional.

**FAC 0 Diferencia Regular, 1 Diferencia Estacional ( $\nabla_{12}DotSuc$ )**



Con la diferencia estacional la FAC ya no presenta estacionalidad pero decae lentamente, indicando que se debe mantener la diferencia regular también

**FAC 1 Diferencia Regular, 1 Diferencia Estacional ( $\nabla\nabla_{12}DotSuc$ )**




Al contar con una diferencia regular y una diferencia estacional se borran los rastros de tendencia y estacionalidad.

Se decide tomar una diferencia regular y una estacional ya que es la que presenta gráficamente un decaimiento más rápido a cero además de ser la que cuenta con menor desviación estándar.

### **3.2 Identificación del modelo**

Apoyados con la FAC y FACP de la serie  $\nabla\nabla_{12}DotSuc$ , se propone un modelo inicial. Para la identificación del modelo ARIMA (p,q) apropiado se calculan y grafican los coeficientes de autocorrelación (FAC) y autocorrelación parcial (FACP). El orden del polinomio autorregresivo (AR) del modelo se determina por el número de coeficientes de autocorrelación parcial que resultan significativamente diferentes de cero y el orden del polinomio de promedios móviles (MA) se determina por el número de coeficientes de autocorrelación significativamente diferentes de cero.

A través de la verificación de supuestos se van adicionando o eliminando parámetros hasta que se encuentra un par de modelos que cumplen de manera razonable con todos los supuestos.

**FACP  $\nabla\nabla_{12}DotSuc$** **3.2.1 Supuestos a verificar**

A continuación se detallan los supuestos a considerar (Guerrero, 2003) y se realiza la verificación de los mismos para cada uno de los modelos mostrados, los cuales fueron seleccionados en función a su “mejor” cumplimiento.

**1.  $\{a_t\}$  tiene media cero**

Verificación:

Se calcula la media aritmética y desviación estándar de los residuos así como el cociente tipo. Si  $|\sqrt{N-d-p} * m(\hat{a}) / \hat{\sigma}_a| < 2$  entonces se dirá que no hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**2.  $\{a_t\}$  tiene varianza constante**

La grafica de residuos contra el tiempo permitirá visualizar fuertes violaciones.

**3. Las variables aleatorias  $\{a_t\}$  son mutuamente independientes**

La FAC residual no debe mostrar valores significativamente distintos de cero, ni de manera individual ni en conjunto. Para probar la hipótesis conjunta de que todos los coeficientes de autocorrelación son simultáneamente iguales a cero, se puede utilizar la estadística Q desarrollada por Box y Pierce. Si la Q calculada excede el valor Q crítico de la tabla ji cuadrada al nivel de significancia seleccionado, se puede rechazar la hipótesis nula de que todos los coeficientes de autocorrelación en conjunto son iguales a cero<sup>1</sup>.

**4.  $\{a_t\}$  tiene distribución normal**

El 95% de los datos provenientes de una normal se deben ubicar entre  $\pm 2$  desviaciones estándar alrededor de la media, esto se podrá ver en la gráfica de residuos contra el tiempo y al graficar el histograma de los mismos.

**5. No existencia de observaciones aberrantes**

En la gráfica de los residuos contra el tiempo se encuentran comúnmente fuera de las bandas de  $\pm 2\hat{\sigma}$ .

---

<sup>1</sup> Véase Econometría, Gujarati Damondar Pág. 787

**6. El modelo es parsimonioso**

Con intervalos de confianza se descarta que algún parámetro sea cero, ya que todos son necesarios para explicar el comportamiento del fenómeno y no pueden ser considerados como iguales a cero.

**7. El modelo es estable en los parámetros**

La correlación alta entre dos parámetros es indicio que el cambio en el valor de un parámetro estimado se compensa con el de otro. Se debe estar alerta de las correlaciones altas (positivas o negativas mayores a 0.5).

**8. Criterios de Akaike y Schwartz**

Ambos criterios sirven para elegir entre modelos rivales y/o comparar modelos con propósitos de pronóstico. Ambos criterios imponen un castigo por incluir un número creciente de regresoras, por lo que al comparar dos o más modelos, siempre se buscará que tanto AIC como SBC sean lo más pequeño posible.

Akaike Information Criterion (AIC)

$$AIC = T * \ln(\text{suma de los cuadrados de los residuales}) + 2n$$

Schwartz Bayesian Criterion (SBC)

$$SBC = T * \ln(\text{suma de los cuadrados de los residuales}) + n * \ln(T)$$

n = número de parámetros estimados (p + q + constante)

T = número de observaciones utilizadas

### 3.3. Obtención del modelo

Después de hacer varias corridas se obtuvo el modelo que mejor cumplió con los supuestos. (Se pueden consultar las diferentes corridas en los anexos)


**Modelo:**  $(1 - \phi_1 B - \phi_2 B^2) \nabla \nabla_{12} T(DotSuc_t) = (1 - \theta_{12} B^{12} - \theta_{17} B^{17}) a_t$

**Supuesto 1.-**  $\{a_t\}$  tiene media cero

$$\left| \frac{\sqrt{N-d-p} * m(\hat{a}) / \hat{\sigma}_a}{\sqrt{45-1-2}} * (-82.48916/937.67435) \right| = |-0.570124| < 2$$

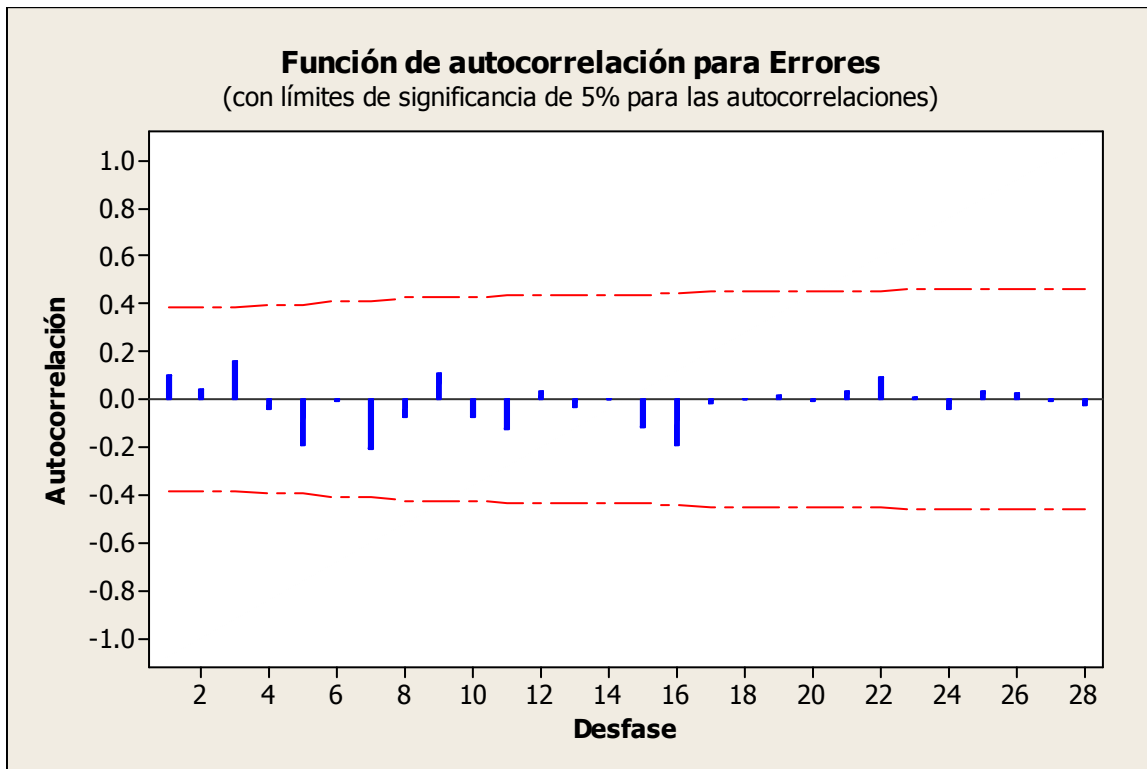
No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero y por lo mismo no se rechaza el supuesto.

**Supuesto 2.-**  $\{a_t\}$  tiene varianza constante



Se aprecia varianza constante en los residuales.

**Supuesto3.- Las variables aleatorias son mutuamente independientes**



De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores


$$Q\text{-Statistic} = 12.30 < 38 = \chi_{25}^2$$

Con el estadístico  $Q$  también se concluye que no existe dependencia de los errores de forma conjunta.




**Supuestos 4 y 5.-  $\{a_t\}$  tiene distribución normal y no existencia de observaciones aberrantes**

**Residuales Estandarizados**



Se observa que el 95% de las observaciones se encuentran entre  $\pm 2$  desviaciones. Se tienen 2 observaciones aberrantes que no sobre pasan el 5% del total de las observaciones. Al observar el histograma se corrobora la distribución normal.

**Histograma de Residuales**



**Supuesto 6.- El modelo es parsimonioso**

<b>Variable</b>	<b>Coefficiente</b>	<b>Intervalo de Confianza</b>
AR{1}	-0.60743296	(-0.2383 , -0.9765)
AR{2}	-0.42307085	(-0.0737 , -0.7725)
MA{12}	-0.70391884	(-0.2524 , -1.1554)
MA{17}	-0.53909600	(-0.0222 , -1.056)

Ningún intervalo de confianza admite al cero como posible valor, por lo que todos los parámetros son significativos.

**Supuesto 7.- El modelo es estable en los parámetros**

**Matriz de Varianzas y Covarianzas**

	AR{1}	AR{2}	MA{12}	MA{17}
AR{1}	0.034056	0.441950	0.285213	0.212026
AR{2}	0.014248	0.030519	0.269094	0.098524
MA{12}	0.011882	0.010612	0.050959	0.269350
MA{17}	0.010112	0.004448	0.015714	0.066789

No existe correlación alta entre parámetros

**Supuesto 8.- Criterios de Akaike y Schwartz**


$$AIC = 29 * \ln(21980829.552) + 2 * 4 = 498.2647$$

$$AIC = 29 * \ln(21980829.552) + 4 * \ln(29) = 503.7339$$

Comparado con los otros modelos, se obtiene el menor valor.

Como última validación del modelo se decidió agregar la gráfica de la FAC y FACP de los errores donde se aprecia que no existen correlaciones altas entre ellos.

Sample: 2004M04 2006M08  
Included observations: 29




	<b>AC</b>	<b>PAC</b>	<b>Q-Stat</b>	<b>Prob</b>
1	0.096	0.096	0.2942	0.588
2	0.07	0.061	0.4572	0.796
3	0.185	0.175	1.6357	0.651
4	-0.09	-0.13	1.9286	0.749
5	-0.22	-0.234	3.7364	0.588
6	0.021	0.044	3.7539	0.71
7	-0.174	-0.117	4.9848	0.662
8	-0.218	-0.143	7.0267	0.534
9	0.04	0.04	7.0974	0.627
10	-0.075	-0.052	7.3606	0.691
11	-0.058	-0.008	7.5297	0.755
12	0.038	-0.062	7.605	0.815

### 3.5 Pronóstico

$$(1 - \phi_1 B - \phi_2 B^2) \nabla \nabla_{12} T(DotSuc_t) = (1 - \theta_{12} B^{12} - \theta_{17} B^{17}) a_t$$

**Dotación de Efectivo a Sucursales entregadas, estimadas y pronóstico**



**Pronóstico Dotaciones de Efectivo a Sucursales**

	Sep-06	Oct-06	Nov-06	Dic-06
- Limite de 90%	13,530.30	13,093.90	13,235.24	20,440.68
Pronóstico	15,072.77	14,750.97	14,972.61	22,430.08
+ Limite de 90%	16,615.25	16,408.04	16,709.98	24,419.49
Observado	15,751.90	16,763.46	18,246.88	23,414.43

## Conclusiones

Obtener el modelo adecuado para estimar las dotaciones de efectivo en sucursales, no fue del todo sencillo, sirvió de mucho tener conocimiento previo de la información presentada para identificar las variaciones y los cambios estructurales presentados en la serie de tiempo. El modelo que se construyó presenta resultados interesantes que aportarán elementos para analizar diversas acciones en torno al objetivo planteado.

Al realizar la estimación de los pronósticos correspondientes, encontramos que el modelo obtenido arroja resultados acorde a lo esperado, pero al contrastarlo con los datos reales de los meses de septiembre, octubre, noviembre y diciembre se observa que durante estos meses, sobre todo octubre y noviembre, la demanda se vio afectada posiblemente por el cambio de sexenio en nuestro país, lo que hizo que ambas observaciones estuvieran por fuera del intervalo de confianza planteado. Por el contrario, el mes de diciembre, se encuentra dentro de la banda de confianza.

El siguiente paso de este trabajo, será encontrar posibles variables explicativas para pasar a un modelo de cointegración, donde se encuentre explicada la demanda de efectivo no sólo por sus rezagos, sino también por algún indicador micro o macroeconómico el cual dé una explicación más certera del flujo de efectivo.

# Anexos

## Modelo 1:


$$(1 - \phi_3 B^3 - \phi_{21} B^{21} - \phi_{22} B^{22}) \nabla \nabla_{12} T(\text{DotSuc}_t) = (1 - \theta_{12} B^{12} - \theta_{17} B^{17} - \theta_{18} B^{18} - \theta_{19} B^{19}) a_t$$

## Supuesto 1

$$\left| \sqrt{N - d - p} * m(\hat{a}) / \hat{\sigma}_a \right| = \left| \sqrt{45 - 3 - 1} * (350.69235 / 1322.95235) \right| = |1.69736| < 2$$

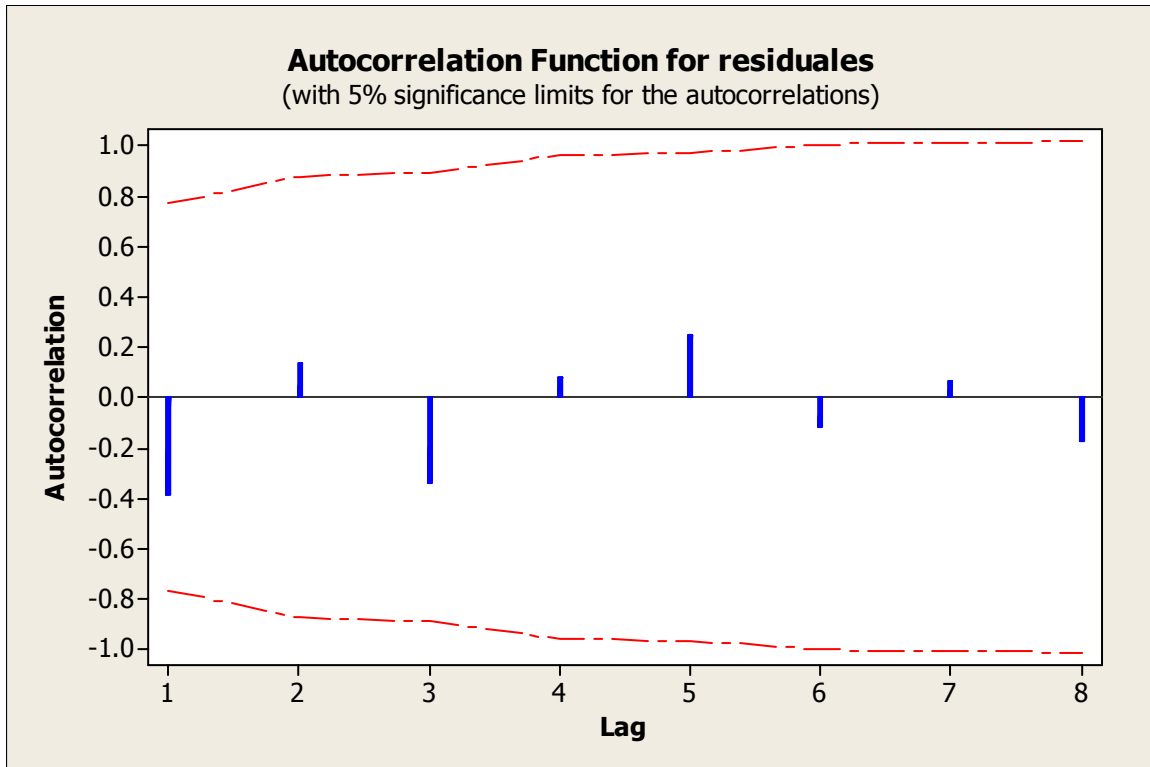
No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

## Supuesto 2



Con el número de residuales obtenidos no se alcanza a percibir varianza constante, pero dado que es un número pequeño de observaciones se seguirá con la verificación de este modelo.

## Supuesto 3




De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores

$$Q\text{-Statistic} = 9.45 > 6 = \chi_2^2$$

Pero con el estadístico de  $Q$  de forma conjunta no se puede concluir que los errores son independientes.

### Supuestos 4 y 5



El 100% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar

### Supuesto 6

Variable	Coficiente	Intervalo de Confianza
<b>AR{3}</b>	<b>-0.108773785</b>	<b>(1.0742 , -1.2917)</b>
<b>AR{21}</b>	<b>0.107245951</b>	<b>(1.0612 , -0.8467)</b>
<b>AR{22}</b>	<b>0.758091697</b>	<b>(1.778 , -0.2618)</b>
<b>MA{12}</b>	<b>0.15</b>	<b>(0.15 , 0.15)</b>
<b>MA{17}</b>	<b>0.15</b>	<b>(0.15 , 0.15)</b>
<b>MA{18}</b>	<b>0.15</b>	<b>(0.15 , 0.15)</b>
<b>MA{19}</b>	<b>0.15</b>	<b>(0.15 , 0.15)</b>

Los intervalos de 3 variables admiten al cero como posible valor, por lo que no son significativas.

Este modelo queda descartado por violar 2 supuestos, no ser parsimonioso y por que los errores no presentan independencia de forma conjunta



**Modelo 2:**


$$\nabla \nabla_{12} T(DotSuc_t) = (1 - \theta_{12} B^{12} - \theta_{17} B^{17} - \theta_{18} B^{18} - \theta_{19} B^{19}) a_t$$

**Supuesto 1**

$$|\sqrt{N-d-p} * m(\hat{a}) / \hat{\sigma}_a| = |\sqrt{45-0-1} * (68.6858/1116.14751)| = |0.408198| < 2$$


No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**Supuesto 2**



Entre la observación 7 y 17 se aprecia una variación considerable, lo que supondría que no presenta varianza constante

## Supuesto 3




De forma individual la observación 3 muestra que su autocorrelación no es significativamente distinta de cero, como se puede apreciar en la gráfica.

$$Q\text{-Statistic} = 33.88 < 40 = \chi_{27}^2$$

Con el estadístico de Q; de forma conjunta no se puede concluir que los errores son independientes.

**Supuestos 4 y 5**



El 95% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar y sólo muestra una observación aberrante

**Supuesto 6**

<b>Variable</b>	<b>Coficiente</b>	<b>Intervalo de Confianza</b>
<b>MA{12}</b>	<b>-0.356018717</b>	<b>(0.1096 , -0.8217)</b>
<b>MA{17}</b>	<b>-0.335097498</b>	<b>(0.235 , -0.9052)</b>
<b>MA{18}</b>	<b>0.00948635</b>	<b>(0.5878 , -0.5688)</b>
<b>MA{19}</b>	<b>0.07745869</b>	<b>(0.6744 , -0.5195)</b>

Todas las variables admiten al cero como posible valor, por lo que no son significativas.

Este modelo queda descartado por no ser parsimonioso y porque presenta autocorrelación significativa con uno de sus errores, además que de forma conjunta no se puede descartar la correlación entre sus errores.

**Modelo 3:**


$$(1 - \phi_1 B^1 - \phi_2 B^2) \nabla \nabla_{12} T(DotSuc_t) = a_t$$

**Supuesto 1**

$$\left| \frac{\sqrt{N-d-p} * m(\hat{a}) / \hat{\sigma}_a}{\sqrt{45-2-1} * (85.90065 / 1050.12009)} \right| = |0.530129| < 2$$


No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**Supuesto 2**



No se observa varianza constante

### Supuesto 3




De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores

$$Q\text{-Statistic} = 16.74 < 40 = \chi^2_{27}$$

Con el estadístico de Q también se concluye que no existe dependencia de los errores de forma conjunta.

**Supuestos 4 y 5**



El 95% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar y sólo muestra una observación aberrante.

**Supuesto 6**

<b>Variable</b>	<b>Coefficiente</b>	<b>Intervalo de Confianza</b>
<b>AR{1}</b>	<b>-0.420377784</b>	<b>(-0.0539 , -0.7868)</b>
<b>AR{2}</b>	<b>-0.32323907</b>	<b>(0.0389 , -0.6853)</b>

Una variable admite al cero como posible valor, por lo que el modelo viola este supuesto.

Este modelo queda descartado por no ser parsimonioso.

**Modelo 4:**


$$(1 - \phi_1 B^1) \nabla \nabla_{12} T(\text{DotSuc}_t) = a_t$$

**Supuesto 1**

$$\left| \sqrt{N - d - p} * m(\hat{a}) / \hat{\sigma}_a \right| = \left| \sqrt{45 - 2 - 1} * (61.14609 / 1082.48365) \right| = |0.370409| < 2$$


No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**Supuesto 2**



No se observa varianza constante

## Supuesto 3




De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores

$$Q\text{-Statistic} = 21.35 < 43 = \chi_{29}^2$$

Con el estadístico de Q también se concluye que no existe dependencia de los errores de forma conjunta.



**Supuestos 4 y 5**



El 95% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar; existiendo 2 observaciones aberrantes.

**Supuesto 6**

Variable	Coficiente	Intervalo de Confianza
AR{1}	-0.289339034	(0.0617 , -0.6404)

La variable admite al cero como posible valor.

Este modelo queda descartado por no ser parsimonioso.

**Modelo 5:**


$$(1 - \phi_1 B^1 - \phi_2 B^2) \nabla \nabla_{12} T(DotSuc_t) = (1 - \theta_{12} B^{12} - \theta_{16} B^{16} - \theta_{17} B^{17}) a_t$$

**Supuesto 1**

$$|\sqrt{N-d-p} * m(\hat{a}) / \hat{\sigma}_a| = |\sqrt{45-2-1} * (-132.77837 / 927.94183)| = |-0.927323| < 2$$


No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**Supuesto 2**



Entre la observación 8 y 14 no se observa varianza constante

## Supuesto 3




De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores

$$Q\text{-Statistic} = 12.27 < 36 = \chi_{24}^2$$

Con el estadístico de Q también se concluye que no existe dependencia de los errores de forma conjunta.

**Supuestos 4 y 5**



El 95% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar; existiendo 2 observaciones aberrantes.

**Supuesto 6**

<b>Variable</b>	<b>Coefficiente</b>	<b>Intervalo de Confianza</b>
<b>AR{1}</b>	<b>-0.642145977</b>	<b>(-0.2791 , -1.0051)</b>
<b>AR{2}</b>	<b>-0.45174277</b>	<b>(-0.1091 , -0.7944)</b>
<b>MA{12}</b>	<b>-0.755484611</b>	<b>(-0.3348 , -1.1762)</b>
<b>MA{16}</b>	<b>-0.303719326</b>	<b>(0.1786 , -0.7861)</b>
<b>MA{17}</b>	<b>-0.503366606</b>	<b>(0.0004 , -1.0072)</b>

Dos variables admiten al cero como posible valor, por lo que no son significativas

Este modelo queda descartado por no ser parsimonioso.

**Modelo 6:**


$$(1 - \phi_1 B^1 - \phi_2 B^2) \nabla \nabla_{12} T(DotSuc_t) = (1 - \theta_{12} B^{12}) a_t$$

**Supuesto 1**

$$\left| \sqrt{N - d - p} * m(\hat{a}) / \hat{\sigma}_a \right| = \left| \sqrt{45 - 2 - 1} * (39.76586 / 993.91591) \right| = |0.259289| < 2$$


No hay evidencia de que la media del proceso de ruido blanco sea distinta de cero.

**Supuesto 2**



Se alcanza a ver varianza medianamente constante

**Supuesto 3**




De forma individual no se muestran valores significativamente distintos de cero, como se puede apreciar en la gráfica de autocorrelación de los errores

$$Q\text{-Statistic} = 17.75 < 39 = \chi^2_{26}$$

Con el estadístico de Q también se concluye que no existe dependencia de los errores de forma conjunta.

### Supuestos 4 y 5



El 95% de los residuos estandarizados están dentro de la banda de  $\pm 2$  desviaciones estándar; existiendo 2 observaciones aberrantes.

### Supuesto 6

Variable	Coficiente	Intervalo de Confianza
AR{1}	-0.512584454	(-0.1437 , -0.8814)
AR{2}	-0.404000834	(-0.0554 , -0.7526)
MA{12}	-0.533927563	(-0.0667 , -1.0012)

Ninguna variable admite al cero en su intervalo de confianza, por lo que existe el modelo es parsimonioso.

**Supuesto 7**

**Matriz de Varianzas y Covarianzas**

	<b>AR{1}</b>	<b>AR{2}</b>	<b>MA{12}</b>
<b>AR{1}</b>	0.034015348	0.377992576	0.272910239
<b>AR{2}</b>	0.012150794	0.030378609	0.170946068
<b>MA{12}</b>	0.011759634	0.006961127	0.054584966

No existe correlación alta entre parámetros

**Supuesto 8.- Criterios de Akaike y Schwartz**

$$AIC = 29 * \ln(25684589.753) + 2 * 3 = 500.7806$$

$$SBC = 29 * \ln(25684589.753) + 3 * \ln(29) = 504.8825$$



## Referencias

Banco de México

<http://www.banxico.org.mx/>

Enders, Walter (1995) 'Applied Econometric Time Series', Canadá

John Wiley & Sons, Inc

Guerrero, Víctor (2003) 'Análisis Estadístico de Series de tiempo Económicas',

Thomson, México.

Gujarati, Damodar N. (2004) 'Econometría' Cuarta Edición, México

Mc Graw Hill