



PRONOSTICO DE LAS REMESAS FAMILIARES DE MÉXICO 2017. APLICACION EMPIRICA MEDIANTE MODELOS ARIMA Y ALISADO EXPONENCIAL.

E. Rosas Rojas¹ J. Gámez Arroyo² R. Pérez Ramírez³ J. C. Baltazar Escalona⁴

Centro Universitario UAEM Valle de México, Km. 11.5 Carretera Atizapán de Zaragoza-Nicolás Romero S/N. Boulevard Universitario S/N Predio San Javier Atizapán de Zaragoza, Estado de México.

Resumen

Pronosticar el valor futuro de una serie de tiempo económica-financiera es una de las cuestiones más importantes en el campo de los negocios y en la investigación. En años recientes, el desarrollo de software estadístico ha permitido implementar de manera sencilla, rápida y eficaz la programación de metodologías complejas y laboriosas para la construcción de pronósticos precisos. Entre los métodos más populares se encuentra: la metodología Box-Jenkins (Modelos ARIMA), y los modelos de Alisado Exponencial. En esta investigación se presenta la secuencia que rige cada uno de los métodos para posteriormente desarrollar sus correspondientes etapas con el objetivo de identificar cuál de los métodos proporciona un pronóstico de mayor precisión para las Remesas de México.

Palabras clave: Modelos ARIMA, Alisado Exponencial.

¹ erosasr@uaemex.mx

² jgameza@uaemex.mx

³ rperezr@uaemex.mx

⁴ jcbaltazare@uaemex.mx

Abstract

Forecasting the future value of an economic-financial time series is one of the most important issues in the field of business and research. In recent years, the development of statistical software has made it possible to implement in a simple, fast and efficient way the programming of complex and laborious methodologies for the construction of accurate forecasts. Among the most popular methods are: The Box-Jenkins methodology (ARIMA models), and the Exponential Smoothing Models. This research presents the sequence that governs each one of the methods to later develop its corresponding stages in order to identify which of the methods provides a more accurate forecast for Remittances in Mexico.

Key words: ARIMA Models, Exponential Smoothing

Introducción

En la gestión empresarial se requiere la elaboración de pronósticos precisos de un gran número de series de tiempo univariadas. Por ello un algoritmo que identifique las etapas esenciales que conforman la elaboración de un pronóstico, es una herramienta esencial. Para que la proyección de los datos sea óptima, se debe determinar el proceso estocástico adecuado para que el modelo capture apropiadamente el comportamiento de la variable. Las metodologías más populares para desarrollar pronósticos de series temporales se basan en el alisado exponencial y en los modelos ARIMA.

† Profesor de Tiempo Completo de la Universidad Autónoma del Estado de México CU Valle de México, Profesor del Posgrado en Economía de la UNAM, Miembro del SNI-CONACYT.

†† Profesora del Centro Universitario UAEM Valle de México.

††† Profesor de Tiempo Completo de la Universidad Autónoma del Estado de México CU Valle de México

†††† Profesor de Tiempo Completo de la Universidad Autónoma del Estado de México CU Valle de México

En las últimas décadas se ha desarrollado una basta propuesta de softwares estadísticos que buscan facilitar la elaboración de pronósticos. La disponibilidad de datos en la actualidad junto con computadoras cada vez más potentes, han guiado a las grandes compañías e instituciones tanto públicas como privadas en el desarrollo de algoritmos que sean capaces de identificar, estimar, diagnosticar y generar proyecciones cada vez más precisas. En el presente trabajo de investigación, se discuten las características y la implementación de los dos métodos comúnmente utilizados para la prospectiva de los datos univariados, y posteriormente se presenta la aplicación empírica para las Remesas de México para

el periodo de enero de 1995 a Febrero de 2017, con lo cuál se busca prospectar los próximos 10 meses del año.

Metodología

Modelos ARIMA

Los modelos de series temporales fueron estudiadas bajo un aspecto determinístico hasta 1927, cuando Yule introdujo la noción de componente estocástico. Box y Jenkins (1970) amalgamaron estas ideas y propusieron un enfoque coherente y versátil que identificaba el ciclo iterativo de tres etapas: identificación, estimación y comprobación del diagnóstico. Cuando se combina un proceso de medias móviles con una ecuación en diferencias lineal para obtener un modelo autorregresivo y de medias móviles (ARMA). Se obtiene lo siguiente:

$$Y_t = a_0 + \sum_{i=1}^p a_i Y_{t-i} + \sum_{i=0}^q B_i E_{t-i} \quad (1)$$

Si las raíces características de la ecuación (1) se encuentran todas dentro del círculo unitario, $\{Y_t\}$ se conoce como modelo ARMA para Y_t . En un modelo ARMA es perfectamente permisible que p y/o q sean infinitos. Si una o más de las raíces características de (1) es mayor o igual que la unidad, la secuencia $\{Y_t\}$ se conoce como proceso integrado y en este caso el modelo es llamado Autorregresivo integrado de medias móviles (ARIMA) (Enders, 2015:50). Este tipo de proceso también se conoce como “no estacionarios”. Y debe aplicarse alguna transformación algebraica que los convierta en estacionarios⁵.

La metodología para modelar los procesos (Autorregresivos Integrados de Medias Móviles) ARIMA fue desarrollada por los estadísticos George Box y Gwilym Jenkins en 1970. Una de las características que la vuelven atractiva es que los procesos ARIMA son una clase muy rica de posibles modelos y es usualmente plausible encontrar un proceso que proporcione una descripción adecuada de los datos (Hyndman, 2008)

El procedimiento original de la metodología ARIMA involucra un proceso iterativo de distintas etapas y se basa en dos grandes principios: El principio de parsimonia, que consiste en elegir siempre el modelo más sencillo que sea suficientemente representativo de los datos. Y el principio del mejoramiento

⁵ Se dice que una serie de tiempo es estacionaria en sentido amplio o débil, si y sólo si satisface tres condiciones:

- Su media es constante en el tiempo. $E(Y_t) = E(Y_{t+T}) = \mu \quad \forall T \in \mathbb{R}$.
- La varianza es constante en el tiempo. $Var(Y_t) = Var(Y_{t+T}) = \gamma \quad \forall T \in \mathbb{R}$.
- La función de autocorrelación es independiente del tiempo. Esta mide la posible dependencia entre un valor observado (Y_t) y otro (Y_{t-k}) que está separado por un intervalo de longitud k .

iterativo, que consiste en partir de un modelo sencillo y factible, al cual se harán mejoramientos sucesivos, hasta llegar a un modelo satisfactorio.

La metodología ARIMA consiste en las siguientes etapas:

- i) Análisis de Estacionalidad y Estacionalidad. Se debe verificar que la serie sea estacionaria e intentar eliminar la variación estacional, si es el caso.
- ii) Identificación del Modelo Tentativo. Se utilizan los correlogramas simple y parcial, con lo que se busca determinar un patrón de las diferentes autocorrelaciones. De igual forma se utiliza el correlograma para evaluar si existe algún tipo de variación estacional, no eliminada por las diferencias estacionales.
- iii) Estimación de Parámetros del Modelo. Para cada modelo tentativo se deberán estimar los parámetros. Esto se puede realizar mediante el método de mínimos cuadrados ordinarios, la ecuación de Yule-Walker o el método de máxima verosimilitud.
- iv) Verificación del Modelo. Se deben calcular los estadísticos clásicos para medir el ajuste de los datos utilizando medidas de error y/o criterios de información (AIC o BIC), la significancia estadística de los coeficientes estimados, pruebas de raíz unitaria sobre los residuos del modelo, también se debe verificar que no exista autocorrelación.
- v) Pronóstico. Los pronósticos serán construidos utilizando el método de iteración adelantada. Es importante señalar que la calidad del pronóstico declina a medida que éste se prolonga.
- vi) Validación del pronóstico. Se debe efectuar una prueba Diebold-Mariano⁶ (1995), en ésta prueba se busca una función objetivo que no sea cuadrática.

Modelos de Alisado Exponencial

Los metodología de alisado exponencial comenzó en la década de 1950, son procedimientos para ajustar una curva apropiada a datos históricos de una determinada serie de tiempo. Existen diversos tipos, como el suavizado exponencial simple, el método lineal de Holt y el método de Holt-Winters, así como sus variaciones (Gujarati, 2011:774). Hasta hace relativamente poco tiempo aun no se desarrollaba un procedimiento que incorporara una estructura de modelación Ord, *et al.* (1997), y Hyndman (2002) han mostrado que todas las metodologías de alisado exponencial presentan pronósticos óptimos para modelos de innovaciones de estado espacial. Los métodos de suavizado exponencial se clasifican de acuerdo a la taxonomía de Taylor (2003), en un total de 15 métodos:

Tabla 1. Métodos de Alisado Exponencial

Componente de Tendencia	Componente Estacional
-------------------------	-----------------------

⁶ La hipótesis nula es que los dos métodos tienen la misma precisión en el pronóstico, mientras que la hipótesis alternativa es que el método 2 es más preciso que el método 1. (En R-Project: `alternative="greater"`).

	N (Ninguna)	A (Aditivo)	M (Multiplicativo)
N (Ninguna)	(N,N)	(N,A)	(N,M)
A (Aditivo)	(A,N)	(A,A)	(A,M)
Ad (Aditivo amortiguado)	(Ad,N)	(Ad,A)	(Ad,M)
M (Multiplicativo)	(M,N)	(M,A)	(M,M)
Md (Multiplicativo amortiguado)	(Md,N)	(Md,A)	(Md,M)

Fuente: Hyndman (2008)

Algunos de estos métodos son mejor conocidos bajo otros nombres. Por ejemplo el modelo correspondiente a la celda (N,N) describe el método de alisado exponencial simple, la celda (Ad, N) describe el método de tendencia amortiguada, la celda (A,A) corresponde al método aditivo de Holt-Winters aditivo, mientras que la celda (A,M) representa el método de Holt-Winters multiplicativo.

Para cada método de Alisado Exponencial Hyndman *et al*, (2008b) se describen dos posibles modelos de innovaciones de estado espacial, uno correspondiente a modelos con errores aditivos y otro para errores multiplicativos⁷. Lo anterior deriva en 30 modelos potenciales. Una vez que el modelo es especificado, se puede estudiar su función de distribución de probabilidad de los valores futuros de la serie, y encontrar la media condicional de una observación futura dado el conocimiento de su pasado. La metodología que se utiliza para estimar los pronósticos de cada modelo tentativo es máxima verosimilitud. La medida de ajuste del pronóstico que se utiliza comúnmente es la media de los errores cuadráticos (MSE, por sus siglas en inglés) o alguna otra medida de error⁸.

El procedimiento que usualmente se sigue para el calculo de los pronósticos mediante la metodología de Alisado Exponencial comprende los siguientes pasos:

- i) Para cada serie de tiempo, aplicar todos los modelos que sean apropiados, optimizando los parámetros (nivel, crecimiento y estacionalidad) del modelo en cada caso.
- ii) Seleccionar el mejor modelo de acuerdo a las medidas de error o con base en el logaritmo de verosimilitud, utilizar los criterios de información de Akaike y de Schwarz⁹ (AIC y BIC, respectivamente) y posteriormente estimar sus parámetros.

⁷ Los modelos de error multiplicativo son útiles cuando los datos son estrictamente positivos, pero no son numéricamente estables cuando los datos contienen ceros o valores negativos.

⁸ También se pueden utilizar las siguientes medidas: ME= (Mean Error) Error Medio; RMSE= (Root Mean Squared Error) Raíz Cuadrada del Error Cuadrático medio; MAE=(Mean Absolute Error) Error Absoluto Medio; MPE= (Mean Percentage Error) Error Medio Porcentual; MAPE=(Mean Absolute Percentage Error) Error Absoluto Medio Porcentual.

⁹ $AIC = T * \log(SRC) + 2 * n$

$BIC = T * \log(SRC) + n * \log(T)$

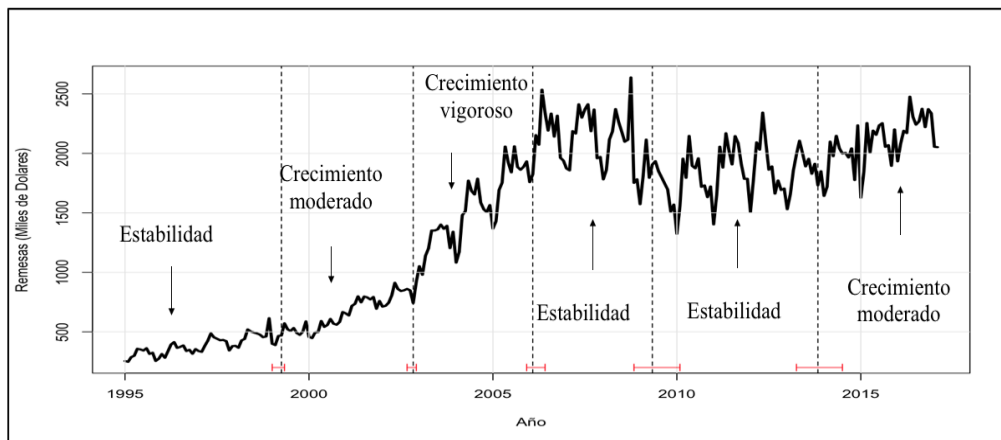
Donde n=número de parámetros estimados (p + q + termino constante) y T=número de observaciones utilizadas.

- iii) Construir el pronóstico puntual utilizando para ello el mejor modelo (con parámetros óptimos).
- iv) Obtener los intervalos del pronóstico para el mejor modelo, utilizando para ello el pronóstico puntual como centro.

Existe un mito ampliamente esparcido de que los modelos ARIMA son más generales que los modelos de Alisado exponencial. Esto no es verdad, de hecho las dos clases de modelos se traslapan. Los modelos de Alisado Exponencial Lineal son todos casos especiales de los modelos ARIMA (Hyndman, 2008a). Sin embargo, los modelos de Alisado Exponencial No Lineal no tienen una contraparte equivalente con los modelos ARIMA. Así, las dos clases de modelos se traslapan y son complementarios; cada uno tiene sus fortalezas y sus debilidades.

A continuación se desarrollan las dos metodologías previamente explicadas para identificar, estimar, verificar y pronosticar el modelo adecuado para las remesas en nuestro país. Su importancia radica en que han mantenido un crecimiento sostenido y que en varios periodos han sobrepasado los niveles de la Inversión Extranjera, con lo que han ganado terreno en el diseño de las políticas gubernamentales.

Gráfica 1. Remesas de México (Enero de 1995 a Febrero de 2017)



Fuente: Elaboración propia con R 3.3.3

Se observa en la gráfica 1 que la entrada de divisas por concepto de Remesas ha crecido de manera sostenida, no obstante se identifican periodos en los que el crecimiento ha sido más vigoroso, otros en los que ha sido moderado y otros más en los que se ha mantenido estable. El primer periodo abarca de principios de 1995 al mes de abril de 1999 y es considerado un periodo de estabilidad, posteriormente se presenta una etapa de crecimiento moderado hasta noviembre de 2002, de esta fecha en adelante comienza una crecimiento vigoroso que se detuvo en febrero de 2006, el cuarto periodo es de estabilidad y terminó en mayo de 2009, éste comportamiento estable se mantuvo en el quinto periodo para concluir


en noviembre de 2013, finalmente, se observa un sexto periodo que aún permanece y que señala un crecimiento moderado de las Remesas.

Resultados y Discusión

Los modelos de Alisado Exponencial son todos no estacionarios. Los modelos con estacionalidad y tendencia no amortiguada tienen dos raíces unitarias; mientras que todos los demás modelos ya sea con tendencia o tendencia amortiguada, tienen una raíz unitaria. La filosofía de los Alisados Exponenciales es que muy pocas series de tiempo son estacionarias. Por lo que si se requiere un modelo estacionario, los modelos ARIMA son mejores (Hyndman, 2008: 12). Una ventaja de los modelos de Alisamiento Exponencial es que pueden ser no lineales. Por lo que las series de tiempo que exhiben un comportamiento no lineal incluyendo heteroscedasticidad podrían ser mejor modelados utilizando modelos de Alisamiento Exponencial. Para datos estacionales, existen muchos más modelos ARIMA que los 30 modelos posibles en la clase de los modelos de Alisado Exponencial.

A continuación se analiza si la serie de tiempo de las Remesas presenta un comportamiento estacional, para ello se filtra en sus componentes: estacionalidad, tendencia y ruido. De la gráfica 2 se identifica un comportamiento claramente estacional, además de la existencia de una tendencia bien definida.

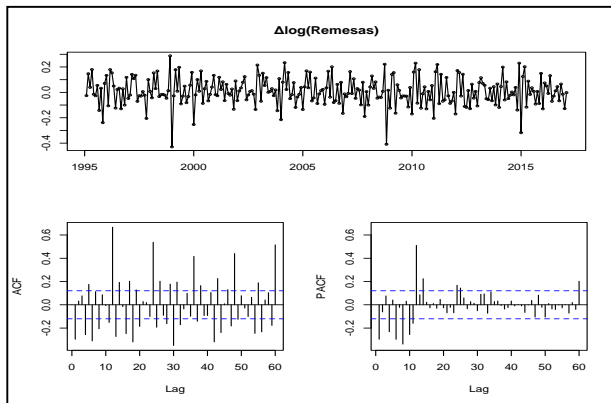
Gráfica 2. Descomposición de la Serie de Tiempo de las Remesas.



Fuente: Elaboración propia con R 3.3.3

Dada la presencia de una raíz unitaria, se procede a transformar algebraicamente la serie de tiempo, para ello se aplican diferencias logarítmicas. Posteriormente se grafica su correlograma simple y parcial, y queda de manifiesto que existe un comportamiento estacional, el cual debe ser incluido en el modelo (Gráfica 3). Respecto a la prueba de raíz unitaria, se desarrolla una prueba Dickey-Fuller Aumentada (DFA) con sus respectivas condicionantes, los estadísticos Tau revelan que la variable a nivel (sin aplicar transformaciones algebraicas) es no estacionaria, mientras que, cuando es transformada claramente se comprueba que la hipótesis nula de estacionariedad es rechazada a un nivel de significancia del 1%, es decir, la diferencia logarítmica de la variable es estacionaria (Tabla 2). Lo anterior establece que se podrían utilizar tanto la metodología de Alisado Exponencial como la metodología de modelos ARIMA.

Gráfica 3. Diferencia logarítmica de las Remesas.



Fuente: Elaboración propia con R 3.3.3

Tabla 2. Prueba DFA para Remesas y Δlog(Remesas)

Variable	Condicionantes	Estadístico Tau	Tau Tablas (1%)
Remesas	Sin Intercepto	0.1138	-2.5800
	Intercepto	-1.6466	-3.4400
	Intercepto y Tendencia	-2.7018	-3.9800
Δlog(Remesas)	Sin Intercepto	-13.654	-2.5800
	Intercepto	-13.792	-3.4400
	Intercepto y Tendencia	-13.858	-3.9400

Fuente: Elaboración propia con R 3.3.3

Se procede a utilizar la librería “forecast” que cuenta con las función “auto.arima” y “ets”. La primera permite definir los parámetros p, d, q considerando diferentes criterios de información como son AIC o BIC. La función indica que se trata de un modelo $SARIMA(2,1,0) \times (2,0,0)_{12}$. Esto significa que el proceso estocástico se representa por un orden de integración uno, un componente autorregresivo ordinario de orden dos y otro componente autorregresivo estacional de orden dos. Lo anterior corrobora lo establecido en la primera etapa, respecto a la fuerte presencia del componente estacional. Por su parte, la segunda indica que parámetros para el componente de error (E), tendencia (T) y estacional (S) que debe ser calibrado corresponde a un modelo $ETS(M, A, M)$, es decir, a un modelo Holt-Winters con errores multiplicativos.

Una vez que se han identificado los modelos óptimos para cada metodología, se deben estimar sus parámetros. En la tabla 3 se presentan los resultados de los coeficientes para el modelo (1), que es el

propuesto como óptimo para esta metodología. Éste muestra que los cuatro coeficientes son estadísticamente significativos a nivel individual, además se muestran sus criterios de información y sus medidas de error. A su vez, en la tabla 4 se expone el modelo óptimo correspondiente a esta metodología, y también se presentan sus estadísticos para la medición del error.

Tabla 3. Método ARIMA

Modelo (1) (SARIMA(2,1,0)x(2,0,0)[12])

	Var. Dep.: $\Delta \log(\text{Remesas})$
	Modelo(1)
	SARIMA
	(2,1,0)x(2,0,0)[12]
AR(1)	-0.4696***
	-0.0604
AR(2)	-0.2794***
	-0.0600
SAR(1)	-0.5064***
	-0.0605
SAR(2)	-0.2709***
	0.0624
Observaciones	266
AIC	3244.56
BIC	3262.46
log likelihood	-1617.28
ME	3.1017
RMSE	105.9723
MAE	72.9934
MPE	0.126

Fuente: Elaboración propia con R 3.3.3

Tabla 4. Método de Alisamiento Exponencial

Modelo (2) (ETS(M,A,M))

	Var. Dep.: Remesas
	Modelo(2)
	ETS (M,A,M)
Parámetros de Alisado	
Alpha	0.5699
Beta	0.0096
Gamma	0.0000
Estados iniciales	
l	288.6292
b	3.578
sigma	0.0689
Observaciones	266
AIC	3843.061
BIC	3903.981
ME	1.6601
RMSE	98.4346
MAE	64.6566
MPE	0.0007

Fuente: Elaboración propia con R 3.3.3

De acuerdo con la suma de residuos cuadráticos (SRC) resulta evidente que el modelo (2) presentan los valores más bajos para estos estadísticos (ME, RMSE, MAE, MPE). Sin embargo, los criterios de información de AIC y BIC señalan que el modelo que mejor estima los verdaderos parámetros es el modelo (1). También es importante señalar que el modelo no presenta un coeficiente de intersección, esto se debe a que al incluir dicho coeficiente resulta no estadísticamente significativo.

En la siguiente etapa se procede a identificar los residuos del modelo seleccionado y sus funciones de autocorrelación correspondientes para garantizar que se trata de un proceso estacionario. Lo anterior también se puede constatar con la prueba de raíz unitaria de Dickey y Fuller Aumentada en sus tres versiones (Tabla 5), estos estadísticos “tau” indica que los residuos del modelo óptimo, tanto para la metodología ARIMA como para la metodología de alisado exponencial, se distribuyen de forma estacionaria, es decir, no presentan raíz unitaria.

Adicionalmente, para garantizar que los residuos de ambos modelos óptimos se comportan de forma independiente, se realizaron pruebas estadísticas para garantizar la no autocorrelación, las hipótesis se desarrollaron con base en Box-Pierce y Ljung Box, ambas demuestran que no existe correlación serial de primer orden en ambos modelos. No obstante, las perturbaciones del primer modelo no presentan éste fenómeno durante los primeros 6 rezagos con un nivel de significancia del 10%, mientras que los residuos del segundo modelo lo presentan a partir del segundo rezago.

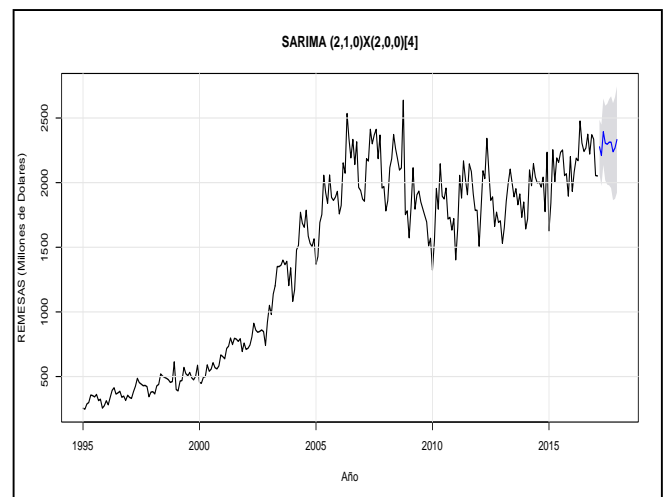
Tabla 5. Prueba DFA para perturbaciones del Modelo (1) y (2)

Variable	Condicionantes	Estadístico Tau	Tau (1%) Tablas
Perturbaciones Modelo (1)	Sin Intercepto	-12.118	-2.5800
	Intercepto	-12.119	-3.4400
	Intercepto y Tendencia	-12.092	-3.9800
Perturbaciones Modelo (2)	Sin Intercepto	-13.877	-2.5800
	Intercepto	-13.963	-3.4400
	Intercepto y Tendencia	-13.979	-3.9400

Fuente: Elaboración propia con R 3.3.3

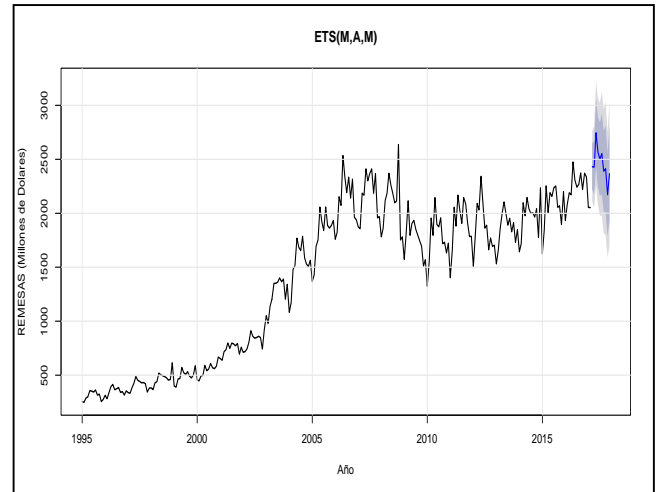
Una vez verificados todos los criterios del diagnostico es posible calibrar el pronóstico de los valores de la secuencia que seguirán las Remesas de México en lo que resta de este año (10 meses). Para esto se construye un pronóstico puntual utilizando ambas metodologías, mediante la técnica de iteración adelantada.

Figura 5. Pronóstico a 10 meses SARIMA



Fuente: Elaboración propia con R 3.3.3

Figura 6. Pronóstico a 10 meses ETS



Fuente: Elaboración propia con R 3.3.3

La capacidad de predicción de un modelo seleccionado es crucial no solo por la calidad en el pronóstico sino para la correcta aplicación de políticas basadas en el mismo. Una forma de corroborar cuál de los modelos seleccionados posee el mejor desempeño para pronosticar es la prueba Diebold-Mariano¹⁰ (DM) (1995), que ofrece una herramienta de evaluación cuantitativa de la exactitud del pronóstico para las Remesas de México.

Tabla 6. Prueba Diebold-Mariano

	Prueba basada en Modelo (1) y Modelo (2)	DM Prueba basada en Modelo (2) y Modelo (1)	DM
Estadístico			
D-M	4.1771	-4.1771	
p-values	0.00001	0.9999	

Nota: La prueba estadística se basa en los Errores Absolutos Cuadráticos. Fuente: Elaboración propia con el programa R 3.3.3

¹⁰ La hipótesis nula es que los dos métodos tienen la misma precisión en el pronóstico, mientras que la hipótesis alternativa es que el método 2 es más preciso que el método 1. (En R-Project: Hipótesis alternativa="greater").

La prueba DM para la comparación de los modelo (1) y (2) establece que la hipótesis nula al nivel de significancia del 5% puede ser rechazada, lo cual demuestra que las diferencias observadas entre los pronósticos desarrollados es significativa, evidenciando que la exactitud del pronóstico del modelo (2), es mayor respecto al modelo (1). Por tanto, se concluye que el modelo que proporciona una mayor capacidad para pronosticar es el modelo de Alisamiento Exponencial. A continuación se presenta el pronóstico puntual de los restantes 10 meses de 2017.

Tabla 7. Pronóstico Remesas de México (Millones de Dólares)

Mes/Año	Modelo (1)	Modelo (2)
Marzo de 2017	2276.923	2432.149
Abril de 2017	2210.752	2428.011
Mayo de 2017	2394.154	2745.366
Junio de 2017	2305.988	2567.926
Julio de 2017	2296.919	2500.002
Agosto de 2017	2312.569	2552.676
Septiembre de 2017	2313.013	2390.382
Octubre de 2017	2239.367	2412.887
Noviembre de 2017	2268.155	2172.821
Diciembre de 2017	2333.454	2365.700

Fuente: Elaboración propia con el programa R 3.3.3

De acuerdo con los resultados pronosticados por el modelo de Alisamiento Exponencial las Remesas de nuestro país alcanzarán un nuevo tope histórico en mayo de 2017, cifrado en 2,745.4 millones de dólares. Los motivos prevención ante la posibles restricciones al envío de remesas a México, junto a una política de apreciación cambiaria son variables clave para el impulso de una cantidad adicional de dinero a nuestro país. A pesar del panorama complicado que se advierte para los migrantes este 2017, a raíz de las medidas proteccionistas anunciadas por Donald Trump, presidente de Estado Unidos, el incremento de las remesas a México se verá impulsado por el dinamismo observado en la economía estadounidense y la baja tasa de desempleo registrado en los meses recientes (4.8 % en enero de 2017).

Conclusiones

La metodología ARIMA es una de las técnicas más versátiles en el pronóstico de series de tiempo estacionales de modelos lineales. La variedad de modelos ARIMA es amplia, y puede representar diferentes tipos de series de tiempo estocásticas estacionales y no estacionales. A través de un proceso iterativo se puede identificar el modelo tentativo, posteriormente estimar sus parámetros, realizar un diagnóstico de verificación, y finalmente, construir un pronóstico que pueda ser validado.

Por su parte, los métodos de alisado exponencial se han utilizado con éxito para generar pronósticos confiables para una amplia gama de series de tiempo desde la década de 1950. En estos métodos, los pronósticos se calculan utilizando promedios ponderados en los que las ponderaciones disminuyen de forma exponencial a medida que las observaciones vienen del pasado lejano, a medida que las ponderaciones son más pequeñas éstas se encuentran asociadas con las observaciones más antiguas. La representación más común de estos métodos es mediante sus componentes de nivel, tendencia y estacionalidad.

Una diferencia fundamental entre estos dos enfoques es que los modelos ARIMA estarán bien especificados siempre y cuando el proceso sea lineal, y el polinomio característico no tenga raíces unitarias, lo que implica que el proceso sea estacionario; mientras que los modelos ETS no se encuentran limitados por la linealidad o la estacionariedad. A pesar de los esfuerzos en la investigación, los estudios existentes sobre la construcción de pronósticos óptimos aún no han llevado a un consenso sobre la supremacía de un enfoque respecto al otro. Lo que se tiene son mecanismos (prueba DM) para identificar la precisión de los pronósticos de cada enfoque. Sin embargo, el desafío para la investigación futura es establecer una base para elegir entre estos y otros enfoques para la predicción óptima de series de tiempo. La evidencia empírica desarrollada en este trabajo de investigación demuestra que el modelo ETS proporciona una mayor exactitud en la construcción del pronóstico para las Remesas de México.

Agradecimientos

Este trabajo de investigación se desarrolló en el marco del proyecto de investigación: “**Análisis de impacto de la política cambiaria en la economía de México**” con registro ante la SIyEA con la clave: 5658 UAEM-CA-96 Ingeniería de Sistemas.

Referencias

1. **Box, G., E., P., & G., M. Jenkins., (1970)**, *Time series analysis: Forecasting and control*, San Francisco: Holden-Day.
2. **Diebold, F.X. & R. Mariano (1995)**. Comparing predictive accuracy. *J. Bus. Econ. Stat.*, 13, 253–265.
3. **Enders, W. (2015)**. *Applied Econometric Time Series*. New York, NY:Wiley.
4. **Gujarati, D., N., & D.C. Porter (2011)**, *Econometria básica-5*, McGraw Hill, New York.

5. **Hyndman R., J, Koehler A., B, Ord JK, Snyder R., D, (2008).** Forecasting with Exponential Smoothing: The State Space Approach. Springer-Verlag.
6. **Hyndman R., J, (2008a).** expsmooth: Data Sets from "Forecasting with Exponential Smoothing".
7. **Hyndman R., J, (2008b).** fma: Data Sets from "Forecasting: Methods and Applications" By Makridakis, Wheelwright & Hyndman, R package version 1.11.
8. **Hyndman R., J, Koehler AB, Snyder RD, Grose S (2002).** "A State Space Framework for Automatic Forecasting Using Exponential Smoothing Methods" International Journal of Forecasting, 18(3), 439-454.
9. **Hyndman R., J., & Y. Khandakar. (2008).** "Automatic time series forecasting: the forecast package for R". Journal of Statistical Software, 26(3).
10. **Ord K, & S. Lowe. (1996).** "Automatic Forecasting", The American Statistician, 50(1), 88-94.
11. **Taylor J. W, (2003).** "Exponential Smoothing with a Damped Multiplicative Trend" International Journal of Forecasting, 19, 715-725.

CODIGO DE PROGRAMACIÓN "R"

#Titulo: Pronóstico de las Remesas de México. Algoritmo para la metodología Box-Jenkins y Alisado Exponencial.

#Programa R por Eduardo Rosas Rojas; Última revisión: Mayol 2017.

```
library(urca);          library(forecast);          library(zoo);          library(lmtest);  
library(sandwich);library(fUnitRoots); library(tseries); library(strucchange)
```

```
#-----
```

Importación de datos y transformación.

```
rm(list=ls())
```

```
print(paste("Ejecutado en: ", date()))
```

```
REM<-read.csv(file.choose(), header=T)
```

```
attach(REM)
```

```
rem<-ts(REM[,2],start=c(1995,1),freq=12)
```

#Se ha guardado la serie de tiempo y puede ser reproducida con c: REM.csv

```
#-----
```

#Identificación de cambios estructurales

```
#rem
```

```
plot(rem)
```

```
bp.rem <- breakpoints(rem ~ 1)
```

```
summary(bp.rem)
```

```
breakdates(bp.rem)
```

```
ci.rem<-confint(bp.rem)
```

```
breakdates(ci.rem)
```

```
ci.rem
```

```
plot(rem, ylab='Remesas (Miles de Dolares)', xlab='Año', type='l', lwd="3")
```

```
grid(lty=1, col=gray(.9))
```

```
lines(ci.rem)
```

```
#-----
```

#Paso 1: Análisis de Estacionariedad y Estacionalidad

Descomposición de la serie en sus componentes : tendencia, estacionalidad y ruido.

```

plot(stl((rem), s.window=4, t.window=12))
# Correlograma simple y correlograma parcial
tsdisplay(rem, lag.max=60, main = "Correlograma Remesas")
#Prueba de Raíz unitaria
urdfTest(rem, lags = 1, type = c("nc"), doplot = T)
urdfTest(rem, lags = 1, type = c("c"), doplot = T)
urdfTest(rem, lags = 1, type = c("ct"), doplot = T)
#Identificación del número de diferencias requerido para convertir la serie en estacionaria
ndiffs(rem, alpha=0.05, test=c("adf"), max.d=2)
# Identificación de diferencias estacionarias.
nsdiffs(rem, m=12, test=c("ocsb"), max.D=2)
#Transformación de diferencias logarítmicas y sus respectivas pruebas
dlrem<-diff(log(rem))
plot(stl((dlrem), s.window=4, t.window=12))
tsdisplay(dlrem, lag.max=60, main = "Correlograma Diferencia(log(Remesas))")
tsdisplay(dlrem, lag.max=60, main = "Δlog(Remesas)")
urdfTest(dlrem, lags = 1, type = c("nc"), doplot = F)
urdfTest(dlrem, lags = 1, type = c("c"), doplot = F)
urdfTest(dlrem, lags = 1, type = c("ct"), doplot = F)
#-----
#Paso 2: Identificación del proceso ARIMA y del Alisado Exponencial
# R cuenta con la función "auto.arima" del paquete "forecast" la cual selecciona
automáticamente el orden del proceso ARIMA minimizando el Criterio AIC y/o BIC
arima_x=auto.arima(rem, max.p=12, max.q=12, max.P=12, max.Q=12, max.d=1, max.D=1,
start.p=2, start.q=2, start.P=1, start.Q=1,stationary=FALSE , seasonal=TRUE,
ic=c("bic"),stepwise=T, test=c("kpss"), seasonal.test=c("ocsb"))
arima_x
#El comando "auto.arima" indica que se trata de un proceso SARIMA (2,1,0)X(2,0,0)[12]
#R también cuenta con el comando "ets" del paquete "forecast" la cual selecciona
automáticamente los valores alpha, beta y gamma, minimizando el Criterio AIC y/o BIC

```



```
rem.ets<-ets(rem, model="ZZZ", damped=NULL, alpha=NULL, beta=NULL,
gamma=NULL, phi=NULL, additive.only=FALSE, lambda=NULL, biasadj=FALSE,
lower=c(rep(0.0001,3), 0.8), upper=c(rep(0.9999,3),0.98),
opt.crit=c("lik","amse","mse","sigma","mae"), nmse=3,
bounds=c("both","usual","admissible"), ic=c("aicc","aic","bic"), restrict=TRUE,
allow.multiplicative.trend=FALSE, use.initial.values=FALSE)
```

#El comando "ets" indica que se trata de un proceso ETS(M,A,M)

#-----

Paso 3: Estimación de los modelos

Usamos el comando "Arima "para realizar inferencia estadística; se especifica el modelo obtenido en el Paso 2, y otros dos modelos propuestos.

```
model1 <- summary(rem.arima<-Arima(rem, order=c(2,1,0),
seasonal=c(2,0,0),include.mean=T, include.drift=F, include.constant=F,
method=c("ML")))
```

```
model2<-ets(rem, model="ZZZ", damped=NULL, alpha=NULL, beta=NULL,
gamma=NULL, phi=NULL, additive.only=FALSE, lambda=NULL, biasadj=FALSE,
lower=c(rep(0.0001,3), 0.8), upper=c(rep(0.9999,3),0.98),
opt.crit=c("lik","amse","mse","sigma","mae"), nmse=3,
bounds=c("both","usual","admissible"), ic=c("aicc","aic","bic"), restrict=TRUE,
allow.multiplicative.trend=FALSE, use.initial.values=FALSE)
```

#-----

#Paso 4: Verificación de los Modelos.

#Algoritmo del Modelo ARIMA Algoritmo

#Se grafican los residuos del modelo óptimo, sus correlograma Simple y Parcial, se aplica una prueba de raíz unitaria, y otra prueba de No autocorrelación.

```
residuos<-(residuals(model1))
```

```
tsdisplay(residuos)
```

```
urdfTest(residuos, lags = 1, type = c("nc"), doplot = F)
```

```
urdfTest(residuos, lags = 1, type = c("c"), doplot = F)
```

```
urdfTest(residuos, lags = 1, type = c("ct"), doplot = F)
```

```
Box.test(residuos, lag=1, type="Ljung")
```

```
Box.test(residuos, lag=2, type="Ljung")
```

```
Box.test(residuos, lag=3, type="Ljung")
```

```

Box.test(residuos, lag=4, type="Ljung")
Box.test(residuos, lag=1, type="Box")
Box.test(residuos, lag=2, type="Box")
Box.test(residuos, lag=3, type="Box")
Box.test(residuos, lag=4, type="Box")
#Algoritmo del Alisado Exponencial
residuosets<-(residuals(model2))
tsdisplay(residuosets)
urdfTest(residuosets, lags = 1, type = c("nc"), doplot = F)
urdfTest(residuosets, lags = 1, type = c("c"), doplot = F)
urdfTest(residuosets, lags = 1, type = c("ct"), doplot = F)
Box.test(residuosets, lag=1, type="Ljung")
Box.test(residuosets, lag=2, type="Ljung")
Box.test(residuosets, lag=3, type="Ljung")
Box.test(residuosets, lag=4, type="Ljung")
Box.test(residuosets, lag=5, type="Ljung")
Box.test(residuosets, lag=1, type="Box")
Box.test(residuosets, lag=2, type="Box")
Box.test(residuosets, lag=3, type="Box")
Box.test(residuosets, lag=4, type="Box")
#-----
# Paso 5: Pronóstico
#ARIMA
# Pronosticamos 10 meses (metodo recursivo) con intervalos al 95% de confianza. Se
grafican los diferentes pronósticos
remarimaf10 = forecast(rem.arima, h=10, level=c(95))
par(mfrow= c(1,1))
plot(remarimaf10, ylab='REMESAS (Millones de Dolares)', xlab='Año', type='l', lwd="2",
main = "SARIMA (2,1,0)X(2,0,0)[4]")

```

```

plot(remarimaf10, ylab='REMESAS (Millones de Dolares)', xlab='Año' , type='l', lwd="2")
grid(lty=1, col=gray(.9))
summary(remarimaf10)

#ALISADO EXPONENCIAL
rem.ets<-ets(rem, model="ZZZ", damped=NULL, alpha=NULL, beta=NULL,
gamma=NULL, phi=NULL, additive.only=FALSE, lambda=NULL, biasadj=FALSE,
lower=c(rep(0.0001,3), 0.8), upper=c(rep(0.9999,3),0.98),
opt.crit=c("lik", "amse", "mse", "sigma", "mae"), nmse=3,
bounds=c("both", "usual", "admissible"), ic=c("aicc", "aic", "bic"), restrict=TRUE,
allow.multiplicative.trend=FALSE, use.initial.values=FALSE)

remetsf10<-forecast(rem.ets,h=10)

plot(forecast(rem.ets,h=10),ylab='REMESAS (Millones de Dolares)', xlab='Año' , type='l',
lwd="2", main="ETS(M,A,M)")

plot(forecast(rem.ets,h=10),ylab='REMESAS (Millones de Dolares)', xlab='Año' , type='l',
lwd="2")

grid(lty=1, col=gray(.9))
summary(remetsf10)

# Se obtiene el pronóstico puntual
#-----

#Paso 6. Validación del Pronóstico

#Se aplica la prueba Diebold-Mariano para identificar el modelo que proporciona el
pronóstico óptimo.

f1<-rem.arima<-auto.arima(rem, max.p=12, max.q=12, max.P=12, max.Q=12, max.d=1,
max.D=1, start.p=2, start.q=2, start.P=1, start.Q=1,stationary=FALSE , seasonal=TRUE,
ic=c("bic"),stepwise=T, test=c("kpss"), seasonal.test=c("ocsb"))

f1p<-forecast(rem.arima, h=10, level=c(95))

f2<-rem.ets<-ets(rem, model="ZZZ", damped=NULL, alpha=NULL, beta=NULL,
gamma=NULL, phi=NULL, additive.only=FALSE, lambda=NULL, biasadj=FALSE,
lower=c(rep(0.0001,3), 0.8), upper=c(rep(0.9999,3),0.98),
opt.crit=c("lik", "amse", "mse", "sigma", "mae"), nmse=3,
bounds=c("both", "usual", "admissible"), ic=c("aicc", "aic", "bic"), restrict=TRUE,
allow.multiplicative.trend=FALSE, use.initial.values=FALSE)

f2p<-forecast(rem.ets,h=10, level=c(95))

accuracy(f1p)

```

```
accuracy(f2p)
```

```
dm.test(residuals(f2p),residuals(f1p),h=10, alternative=c("greater"), power=2)
```

```
dm.test(residuals(f1p),residuals(f2p),h=10, alternative=c("greater"), power=2)
```

```
f1p
```

```
f2p
```