

Pronostico del tipo de cambio con un modelo SARIMA

García Rodríguez L.A.

Septiembre 2023

1 Introducción

La economía global se encuentra en constante evolución, y uno de los factores clave que afecta a las relaciones comerciales y financieras entre países es el tipo de cambio. El tipo de cambio juega un papel fundamental en la determinación de los precios relativos de las monedas y, por lo tanto, tiene un impacto significativo en el comercio internacional, la inversión extranjera y la estabilidad económica de una nación. En el caso de México, un país con una economía altamente dependiente de su comercio exterior, el tipo de cambio es de especial importancia.

A lo largo de las últimas décadas, México ha experimentado fluctuaciones significativas en su tipo de cambio, lo que ha planteado desafíos y oportunidades tanto para el gobierno como para las empresas que operan en el país. La capacidad de pronosticar con precisión el tipo de cambio se ha convertido en un objetivo clave para tomar decisiones informadas en los ámbitos de la política económica y comercial.

2 Revisión de la literatura

La literatura reciente se centra en el análisis y modelado del tipo de cambio peso-dólar, abordando diferentes metodologías y enfoques en el período comprendido principalmente entre 2016 y 2018. Los estudios revisados incluyen un modelo de predicción para la economía mexicana basado en el Enfoque Monetario de la Balanza de Pagos, un análisis Bayesiano para la selección del modelo más adecuado en el pronóstico de las tasas de cambio, y la aplicación de un modelo ARIMA en ventanas temporales deslizantes para ajustar cambios estructurales.

2.1 "Un modelo de predicción del tipo de cambio spot para la economía mexicana"

Autor: María de la Paz Guzmán Plata

Objetivos de la investigación: Desarrollar un modelo predictivo para el tipo de cambio spot en la economía mexicana, fundamentado en el Enfoque Monetario de la Balanza de Pagos, con el fin de entender y anticipar los movimientos de este tipo de cambio.

Metodología de modelación: Se emplea un modelo econométrico de largo plazo basado en el Enfoque Monetario de la Balanza de Pagos, complementado por un modelo de corto plazo que incorpora variables macroeconómicas y financieras significativas. Para ello, se utilizan técnicas como la cointegración de Johansen y el método de Engle y Granger, entre otros, buscando establecer relaciones estables a largo plazo y dinámicas de ajuste a corto plazo.

Esta investigación se centra en el análisis y predicción del tipo de cambio spot en México, utilizando un enfoque que combina teoría macroeconómica y análisis financiero. Se enfatiza la importancia de integrar distintas variables y técnicas econométricas para una predicción más precisa y relevante en el contexto mexicano. El estudio aporta un modelo detallado, con aplicabilidad en la economía y las finanzas.

Guzmán Plata, M. de la P. (2006). Un modelo de predicción del tipo de cambio spot para la economía mexicana. Análisis Económico, XXI(47), 95-129.

2.2 "Modelado y pronóstico del tipo de cambio de México (Peso/Dólar): Un enfoque Bayesiano para la selección del modelo"

Autor: Gustavo Cabrera González, Universidad de Guadalajara, México

Objetivos de la investigación: Analizar el modelado econométrico y la proyección de las tasas de crecimiento del tipo de cambio nominal (Peso/Dólar) de 1995 a 2018. Se busca determinar el mejor ajuste de los datos entre enfoques econométricos lineales y no lineales, utilizando métodos de simulación Bayesiana y parámetros de cambio de régimen Markovianos.

Metodología de modelación: Se emplea simulación Bayesiana para comparar modelos econométricos lineales y no lineales. Se introduce un enfoque de

cambio de régimen Markoviano para determinar el ajuste óptimo a los datos.

La investigación demuestra que en el análisis de tasas de crecimiento diarias y mensuales del tipo de cambio, existen períodos con distintos niveles de volatilidad. Se concluye que los modelos lineales autorregresivos no son adecuados para estos datos, y se evidencia la presencia de parámetros dependientes del estado. Se aplica un enfoque de ponderación óptima a modelos de cambio de régimen Markovianos para analizar los errores de pronóstico.

*Cabrera González, G. (2019). Modelado y pronóstico del tipo de cambio de México (Peso/Dólar): Un enfoque Bayesiano para la selección del modelo. *Revista Mexicana de Economía y Finanzas Nueva Época, 14*(2), 203-219. DOI: 10.21919/remef.v14i2.307*

2.3 "Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes"

Autores: Rey Francisco Ayala Castrejón y Christian Bucio Pacheco, Universidad Autónoma del Estado de México

Objetivos de la investigación: Generar un abanico de pronósticos del tipo de cambio peso-dólar mediante un modelo ARIMA(111) en el periodo 2016-2017, utilizando ventanas temporales deslizantes y ajustes por cambio estructural para mejorar la precisión del pronóstico.

Metodología de modelación: Utilización del modelo ARIMA(111) aplicado a través de ventanas temporales deslizantes para capturar variaciones en el tiempo y ajustar por cambios estructurales. Se emplea este enfoque para generar pronósticos a corto plazo y analizar su precisión.

La investigación demuestra que la utilización de ventanas temporales deslizantes en el modelo ARIMA(111) mejora la precisión del pronóstico del tipo de cambio peso-dólar. Se observa que este enfoque es particularmente efectivo en contextos de volatilidad y cambios estructurales en los datos, proporcionando un método más dinámico y adaptable para el pronóstico económico.

Ayala Castrejón, R. F., & Bucio Pacheco, C. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. Revista Mexicana de Economía y Finanzas, 15(3), 331-354. DOI: 10.21919/remef.v15i3.466.

3 Hipótesis

El objetivo principal de este documento es realizar un análisis del rendimiento de un modelo econométrico y su pronóstico del tipo de cambio en México. Dicho modelo es el modelo SARIMA, el cual es un modelo estadístico del análisis de series de tiempo, que suponemos, tiene la capacidad de predecir el comportamiento del tipo de cambio mexicano.

4 Metodología

Como se menciono anteriormente, el modelo a utilizar será un SARIMA, que es un modelo auto regresivo integrado y de medias móviles estacional. Para la construcciones de este, se seguirá la siguiente metodología:

Recolección de datos La recolección de datos será de una sola fuente y una sola variable. Extraeremos el tipo de cambio (pesos por dólar) de la serie historia del período de 1993 a 2023, con periodicidad mensual. Nuestra fuente es la serie histórica del tipo de cambio que proporciona BANXICO en su sitio web.

Gráfica de la serie Una vez recolectados los datos, se gráfica la serie para poder observar el tipo de cambio y su evolución en el tiempo.

Descomposición de la serie Posteriormente descompondremos la serie para analizar su tendencia, su estacionalidad y sus residuos.

Pruebas de estacionariedad Para poder realizar un correcto modelo, debemos verificar que las series sean estacionarias, por lo que se usarán dos test de estacionariedad, el test Dickey Fuller aumentado y el test Phillips Perron. Y posteriormente se determinará el orden de integración.

Funciones de auto correlación Para determinar los parámetros p y d del modelo, revisaremos las funciones de autocorrelación (ACF) y (PACF).

Construcción del modelo y determinación de la estacionalidad Una vez determinados los parámetros p , q y d . Procederemos a encontrar la estacionalidad y el mejor modelo, usando como criterio la mayor log verosimilitud y los menores criterios de información de bayes.

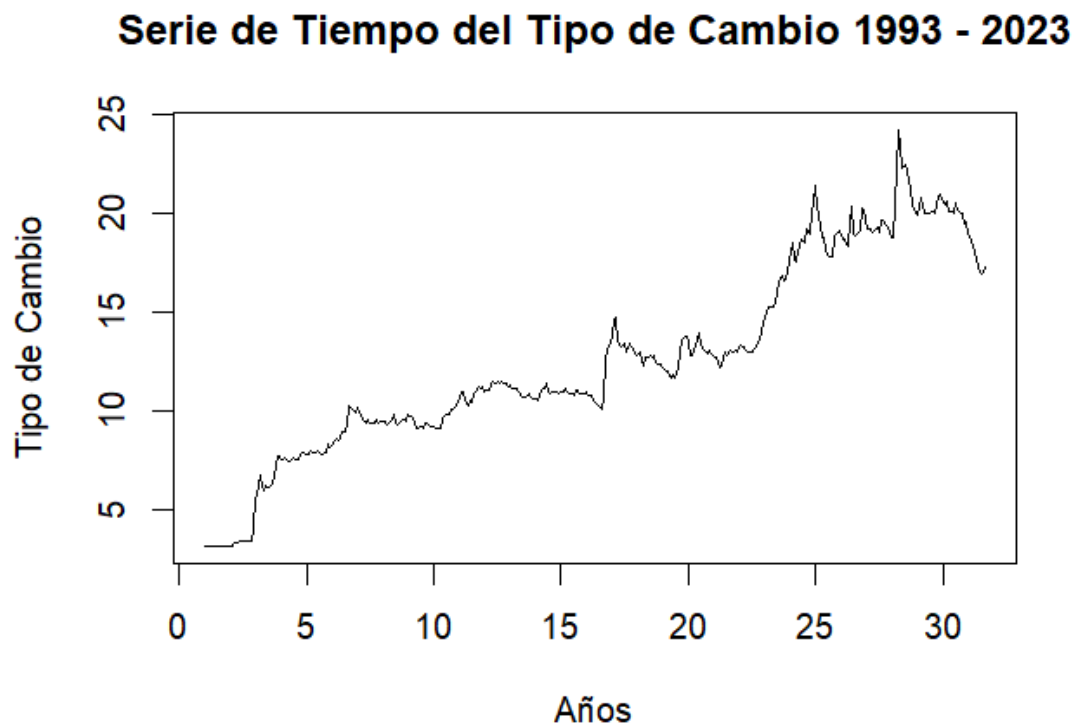
Pronósticos Procederemos a generar pronósticos para los próximos 6 periodos con el modelo construido.

5 Resultados

5.1 Gráfica de la serie

Empleamos los datos del tipo de cambio de 1993 a septiembre 2023, con periodicidad mensual. La evolución del tipo de cambio en el tiempo se ve de la siguiente forma:


Figure 1: Tipo de cambio de 1993 a 2023



5.2 Descomposición de la serie

Ahora se procede a descomponer la serie en tendencia, estacionalidad y residuos

Figure 2: Descomposición del tipo de cambio



Lo anterior es la descomposición aditiva de la serie, en ella podemos identificar, que nuestra serie efectivamente tiene tendencia, por lo que posiblemente no sea estacionaria, además, también identificamos la estacionalidad, la cual parece ser anual, es decir, que el ciclo ocurre una vez al año, y la parte de residuos observamos aquello que no se explica por la tendencia ni la estacionalidad.

5.3 Pruebas de estacionariedad

A continuación, se muestran los contrastes de hipótesis de estacionariedad.

Figure 3: Contraste de Dickey Fuller aumentado

Augmented Dickey-Fuller Test

```
data: TC
Dickey-Fuller = -2.3995, Lag order = 7, p-value = 0.4083
alternative hypothesis: stationary
```

Figure 4: Contraste de Phillips Perron

Phillips-Perron Unit Root Test

```
data: TC
Dickey-Fuller Z(alpha) = -14.556, Truncation lag parameter = 5,
p-value = 0.2954
alternative hypothesis: stationary
```

Como puede interpretarse en ambos resultados, el p-value es mayor al nivel de significación de 0.05, por lo que no se rechaza la hipótesis nula de ambos contrastes, que es la presencia de raíz unitaria, es decir, no estacionariedad.

Procedemos entonces a aplicar una diferenciación a la serie, con el objetivo de que esta se convierta en estacionaria, así que se vuelven a aplicar los test a las series diferenciadas.

Figure 5: Contraste de Dickey Fuller aumentado a la serie tras la primera diferenciación

Augmented Dickey-Fuller Test

```
data: TC_1d
Dickey-Fuller = -7.6143, Lag order = 7, p-value = 0.01
alternative hypothesis: stationary
```

Puede observarse en las salidas, que la serie tiene un p.valor menor al nivel de significación en ambas pruebas, por lo que se rechaza la hipótesis nula y se acepta la alternativa, ausencia de raíz unitaria y por lo tanto estacionariedad. Esto nos

Figure 6: Contraste de Phillips Perron a la serie tras la primera diferencia

Phillips-Perron Unit Root Test

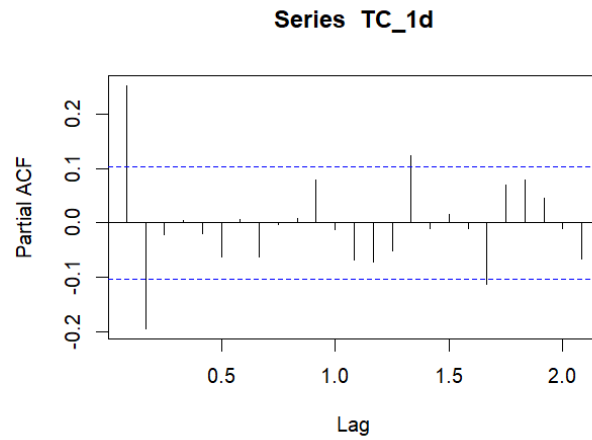
```
data: TC_1d
Dickey-Fuller Z(alpha) = -236.87, Truncation lag parameter = 5,
p-value = 0.01
alternative hypothesis: stationary
```

indica, que como en nuestro modelo, las series deben ser estacionarias, estas requieren un orden de integración 1.

5.4 Funciones de autocorrelacion


Ahora procederemos a observar las gráficas de autocorrelacion ACF y PACF para determinar el orden de los parámetros p y d del modelo.

Figure 7: PACF



En la función de autocorrelacion parcial, encontramos 2 rezagos significativos, por lo que nuestro modelo tendrá un orden $p=2$

Figure 8: ACF



Mientras que en la función de autocorrelacion, encontramos 4 rezagos significativos, por lo que nuestro modelo tendrá un orden $q=2$

5.5 Construcción del modelo

Una vez revisado las funciones de autocorrelacion, y la estacionariedad, así como la estacionalidad, podemos proceder a especificar nuestro modelo SARIMA, que en primera instancia será un modelo ARIMA de orden (2,1,4). Posteriormente vamos a iterar entre un rango 5 para encontrar los parámetros P,D,Q respectivos a la estacionalidad, para ello buscaremos un modelo con la mayor log verosimilitud y los menores criterios de información.

Una vez realizada la iteración encontramos el siguiente modelo:

Figure 9: Modelo SARIMA

```
SARIMA <- Arima(Datos_Econometria1_xts$Tipo.de.cambio,
                order = c(2, 1, 4),
                seasonal = list(order = c(1, 0, 2), period = 12),
                include.constant = TRUE)
```

De tal modo, que el modelo planteado es un SARIMA (2,1,4),(1,0,2)[12], cuyos resultados se muestran a continuación:

Figure 10: Resumen del modelo SARIMA

```
Series: TC
ARIMA(2,1,4)(1,0,2)[12] with drift

Coefficients:
      ar1      ar2      ma1      ma2      ma3      ma4      sar1      sma1
s.e.  -1.0372  -0.8949  1.3608  1.1674  0.1305  -0.1241  0.9986  -0.9539
      sma2      drift
s.e.  -0.0375  0.0382
      0.0569  0.0327

sigma^2 = 0.1489:  log likelihood = -171.27
AIC=364.53  AICc=365.27  BIC=407.52

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE
Training set -0.002641857  0.3800591  0.240832  0.01121089  1.918649  0.2194506
              ACF1
Training set 0.007079214
```

5.6 Pronósticos

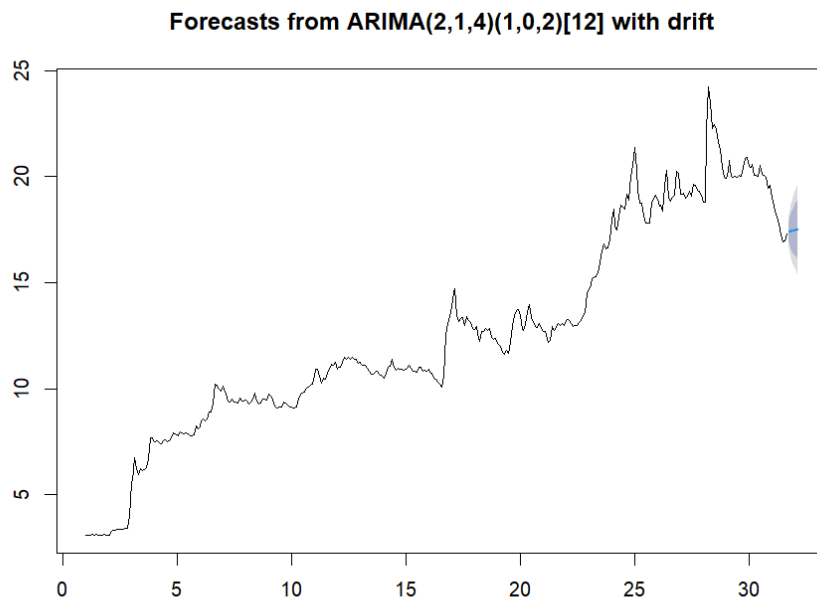
Los valores pronosticados en el periodo de 6 meses, son los siguientes:

La gráfica de pronósticos, junto con los intervalos de confianza se muestran a continuación:

Figure 11: Resumen del modelo SARIMA

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Oct	31	17.41596	16.91840	17.91353	16.65500	18.17693
Nov	31	17.44172	16.61735	18.26609	16.18095	18.70249
Dec	31	17.46219	16.42803	18.49635	15.88058	19.04380
Jan	32	17.50136	16.31565	18.68707	15.68797	19.31475
Feb	32	17.50252	16.17635	18.82869	15.47432	19.53072
Mar	32	17.53972	16.07613	19.00330	15.30136	19.77808

Figure 12: Pronósticos del modelo SARIMA



6 Discusión

El modelo SARIMA construido, es un modelo útil, capaz de pronosticar un intervalo certero para las proyecciones del tipo de cambio. Sin embargo, hay que considerar que es un modelo complejo y no precisame parsimonioso. Y que esto no significa que por ser complejo es mejor, pues hay pruebas estadísticas que no fueron consideradas para la de los resultados del modelo, como podrían ser la normalidad de los residuos o la heterocedasticidad en los errores. También hay que mencionar que este tipo de modelos univariantes no tiene en consideración

otras variables exógenas que podrían ayudar a mejorar los pronósticos, ya que estos modelos univariantes no pueden predecir algún movimiento, o choque externo que pueda impactar en el comportamiento del tipo de cambio, por lo que podríamos considerar modelar con otra metodología, como los son los modelos SARIMAX, que consisten en agregar información de variables exógenas teóricamente causales de la variable endógena.

7 Conclusiones

Se ha identificado que un modelo SARIMA, es capaz de pronosticar el comportamiento del tipo de cambio, ya que los valores reales del tipo de cambio en los periodos comprobables cayeron dentro del intervalo de confianza de el modelo, lo que lo hace un modelo útil. Sin embargo hay que mencionar que este tipo de modelos univariantes no tiene en consideración otras variables, por lo que nos incapaces de predecir algún movimiento, o choque externo que pueda impactar en el comportamiento del tipo de cambio, por lo que aunque es útil, no es la mejor manera de modelar esta variable.

8 Referencias

Ayala Castrejón, R. F., & Bucio Pacheco, C. (2020). Modelo ARIMA aplicado al tipo de cambio peso-dólar en el periodo 2016-2017 mediante ventanas temporales deslizantes. Revista Mexicana de Economía y Finanzas, 15(3), 331-354. DOI: 10.21919/remef.v15i3.466.

*Cabrera González, G. (2019). Modelado y pronóstico del tipo de cambio de México (Peso/Dólar): Un enfoque Bayesiano para la selección del modelo. *Revista Mexicana de Economía y Finanzas Nueva Época, 14*(2), 203-219. DOI: 10.21919/remef.v14i2.307*

Guzmán Plata, M. de la P. (2006). Un modelo de predicción del tipo de cambio spot para la economía mexicana. Análisis Económico, XXI(47), 95-129.