

Prediciendo series de tiempo de variables económicas dominicanas

Italo López

Departamento de Estudios Económicos
Superintendencia de Bancos de la República Dominicana

Julio 2023

Abstracto

En esta investigación estudiamos la predicción de seis variables que indican el devenir en el corto plazo de la economía dominicana (Remesas, IMAE, Turistas, Cotizantes AFP, IPC y Crédito Privado). Para lo mismo se utilizan varios algoritmos de la Econometría Clásica. Se evalúan las predicciones de los mismos con *Time Series Cross-Validation* y se le realiza una diagnosis para decidir sobre el mejor método de predicción entre los considerados para cada variable.

Palabras clave: *Predicción, Economía Dominicana, Time Series Analysis*

Índice

1	Introducción	3
2	Revisión de la literatura	3
3	Datos	5
4	Metodología	5
4.1	Modelos utilizados	6
4.2	Proceso de evaluación y diagnosis de los modelos	7
5	Resultados	10
5.1	Cotizantes a las AFP	10
5.2	Indice Mensual de Actividad Económica	13
5.3	Remesas	15
5.4	Crédito Privado en Moneda Nacional	17
5.5	IPC	20
5.6	Llegada de Turistas	24
6	Conclusión	26
	Referencias	27
	Anexo	31
.0.1	Cotizantes AFP	31
.0.2	Indice Mensual de Actividad Económica	38
.0.3	Remesas	45
.0.4	Crédito Privado en Moneda Nacional	53
.0.5	IPC	63
.0.6	Llegada de Turistas	73

1. Introducción

En este paper presentamos la predicción de un grupo selecto de variables clave que tienen importancia para los observadores de la economía dominicana, los cuales necesitan frecuentemente generar predicciones estadísticamente rigurosas para apoyar la toma de decisiones.

Para estos fines analizamos e implementamos una batería de modelos con la finalidad de predecir el nivel futuro de cada variable en un rango de uno a seis meses. La elección final del enfoque a ser seguido en general depende del problema particular y de la data utilizada. Los métodos clásicos univariantes y multivariantes tienen la ventaja de ser considerados más fácilmente interpretables, adecuados para muestras más cortas y entendibles, pero no tienen muchas veces flexibilidad para manejar patrones dinámicos complejos. Hay otros métodos dignos de considerar pero al contrario de los métodos clásicos tienen la desventaja de que son difíciles de interpretar y en muchas ocasiones necesitan de una gran cantidad de data.

Con la batería de modelos elegida, hacemos un ejercicio de *Time Series Cross-Validation*, lo que nos permite evaluar cada uno de los modelos y diagnosticarlos con fines de elegir el mejor para cada una de las variables consideradas.

Este documento se encarga precisamente de explicar la documentación, procesamiento y metodología usada para la creación de predicciones para un conjunto de variables que indican el devenir de la economía dominicana en el corto plazo.

El presente artículo se desarrolla de la siguiente manera: En la segunda sección hacemos un repaso de la literatura relevante; la sección tercera describe los datos y la cuarta los modelos econométricos y su identificación. La quinta describe la diagnosis, la sexta contiene los resultados y la séptima concluye el cuerpo del texto. Detalles que respaldan los resultados se muestran en el Anexo.

2. Revisión de la literatura

Si bien la necesidad de generar predicciones proviene de mucho tiempo atrás, se puede decir que la literatura moderna de predicciones de series de tiempo comienza con la metodología clásica de Box-Jenkins (1970) de los modelos ARIMA, que busca encontrar el mejor ajuste de una serie temporal, a fin de que los pronósticos sean más acertados.

Durante buena parte de los 1970's y 1980's esta metodología se consideró un *benchmark*, pero numerosos métodos han surgido, tanto clásicos como no clásicos, para hacer predicciones de series de tiempo que proveen resultados satisfactorios y que logran ser competitivos con esta metodología clásica.

Aunque la metodología Box-Jenkins de los modelos ARIMA se puede considerar el punto de partida de la literatura moderna de predicción de series de tiempo, otros modelos se han desarrollado dentro del paradigma clásico para hacer predicciones. El propio modelo básico de regresión lineal puede ser utilizado para tales fines siempre y cuando las variables exógenas sean conocidas para el horizonte de predicción relevante (Diebold, 2017). A partir de los años 1980 cobraron relevancia, sobre todo en aplicaciones macroeconómicas, el uso de los modelos VAR introducidos por (Sims, 1980) y un poco más tarde los modelos VECM introducidos por (Engle y Granger, 1987) y (Johansen y Juselius, 1990), entre muchos otros modelos que han surgido.

En general, cuando realizamos predicciones, vemos las series de tiempo como compuestas de varios elementos: la tendencia, que describe movimientos de baja frecuencia, el residuo, representando movimientos de muy alta frecuencia, y la estacionalidad o el ciclo que contienen movimientos de frecuencia intermedia (Diebold, 2017). La tendencia puede ser modelada de manera determinista (Diebold, 2017) o de manera estocástica, al igual que la estacionalidad. El método utilizado para modelar cada uno de los componentes dependerá de la propia data.

Un punto importante a tener en cuenta a la hora de hacer predicciones es la evidencia que existe sobre los procedimientos de combinación de predicciones. Desde al menos el artículo clásico de Bates y Granger (1969) "The Combination of Forecasts" se sabe que la combinación de predicciones muchas veces mejora la precisión de predicciones puntuales. Esto ha sido corroborado por las competencias de predicciones (Hyndman, 2020) y la experiencia de los últimos 50 años (Atiya, 2020), que ha dado como resultado un gran número de métodos para generar combinaciones de predicciones. Los métodos de combinaciones han evolucionado de simples métodos sin necesidad de estimación a métodos más sofisticados como time-varying weights, métodos no-lineales, cross-learning, etc. (Hyndman y Kang, 2022).

Otro punto importante mencionado en la literatura es la validación de los algoritmos

predictivos. La idoneidad de un modelo predictivo se analiza de varias formas. Se puede analizar la validez de la predicción puntual de un modelo, así como de la precisión de los intervalos de predicción y la precisión de la predicción de densidad. Esta teoría está bien establecida. Véase (Diebold, 2017).

En cuanto a la literatura dominicana sobre predicción es de destacar el trabajo de (Jimenez Polanco y Ramírez Escoboza, 2015) donde se predice la actividad económica con un modelo multivariable utilizando datos de Encuestas de Opinión Empresariales y el Índice Mensual de Actividad Económica.

3. Datos

La data utilizada proviene de las publicaciones del Banco Central de la República Dominicana (BCRD) y de la Superintendencia de Pensiones (SIPEN). Todas las series son de frecuencia mensual.

Las series en cuestión son seis y pretenden ser un indicador del devenir de la economía dominicana en el corto plazo. Las mismas son: Remesas, Índice Mensual de Actividad Económica (IMAE), Llegada de Turistas, Índice de Precios al Consumidor (IPC), Crédito Privado en Moneda Nacional y Cotizantes a las AFP.

Variable	Frecuencia	Desde	Número de Observaciones	Hasta	Fuente
Cotizantes AFP	Mensual	sep-03	236	abr-23	SIPEN
IMAE	Mensual	ene-07	194	feb-23	BCRD
IPC	Mensual	ene-84	471	mar-23	BCRD
Llegada de Turistas	Mensual	ene-78	543	mar-23	BCRD
Remesas	Mensual	ene-10	159	mar-23	BCRD
Crédito	Mensual	ene-07	196	abr-23	BCRD

Tabla 1: Variables consideradas para ejercicio de predicción

4. Metodología

Con el fin de determinar la predicción óptima de los siguientes 6 períodos para las series de datos mencionadas anteriormente, se calibra de manera independiente una serie de modelos y luego se somete cada uno a un conjunto de pruebas para determinar el modelo óptimo de predicción para cada serie.

4.1 Modelos utilizados

Con el fin de generar predicciones de uno a seis meses para las series antes señaladas, se decidió considerar modelos univariados de la econometría clásica. Los modelos utilizados son los siguientes:

- **Box-Jenkins SARIMA:**

En ecuaciones el modelo es en la población:

$$\phi_p(B)\Phi_P(B)\Delta^d\Delta_S^D y_t = c + \theta_q(B)\Theta_Q(B)e_t$$

donde y_t es la variable escalar observable, c es una constante, $\phi_p(B)$ es un polinomio en el operador de rezagos de orden p , Δ es el operador de diferencias operado d veces, $\theta_q(B)$ es un polinomio en el operador de rezagos de orden q , $\Phi_P(B)$ es un polinomio en el operador de rezagos estacionales de orden P , Δ_S^D es el operador de diferencias estacionales operado D veces, $\Theta_Q(B)$ es un polinomio en el operador de rezagos estacionales de orden Q y e_t es un shock.

Para este modelo se identifica la configuración de los parámetros siguiendo la metodología clásica de Box-Jenkins. Véase (Diebold, 2017).

- **Minimum AIC ETS:** El ETS asigna ponderaciones exponencialmente decrecientes para las observaciones más recientes a las más antiguas. En otras palabras, cuanto más antiguos son los datos, menos prioridad (“peso”) se le da a los datos; los datos más nuevos se consideran más relevantes y se les asigna mayor peso. Los parámetros de suavizado (constantes de suavizado) de cada uno de los componentes de la serie, generalmente indicados por α , γ y β , determinan las ponderaciones de las observaciones.

Para este algoritmo se determina previamente el tipo de descomposición que aplica a la variable de modo que se elige el tipo de *Exponential Smoothing* apropiado y se estiman los parámetros pertinentes que minimizan el Akaike Information Criterion (AIC) del modelo. Véase (Hyndman y Asthanasopoulos, 2021).

- **Grid/Best ARIMA:** Este consiste en un ARIMA (SARIMA sin los parámetros estacionales) identificando la configuración de los parámetros no según Box-Jenkins si no según el cual alcance el mejor ajuste fuera de muestra en el training set medido por el menor *Mean Square Error*. Una vez identificado el orden se estima de la manera usual y se generan las predicciones de la manera usual.

- **Grid/Best ETS:** lo análogo a lo anterior para el caso del *Exponential Smoothing* con componente de tendencia, estacional y de residuo. Esto es, se establece un grid de los parámetros que controlan el nivel de ponderación de las partes que componen la serie y aquella configuración que maximice el ajuste fuera de muestra es la elegida.
- **Direct Forecast Regression:** Esta es una regresión que implemente un *direct forecast*. En ecuaciones el modelo es simplemente lo siguiente:

$$y_{t+h} = a + by_t + e_{t+h}$$

para cada $h = 1, \dots, 6$. Esta ecuación puede ser estimada simplemente por la regla de mínimos cuadrados (MICO), aunque otros métodos de estimación también son válidos.

A partir de los modelos individuales descritos arriba, se hicieron combinaciones de predicciones (o *ensemble forecast*, en inglés).

Las combinaciones se determinaron mediante los siguientes dos métodos (Diebold, 2017):

- **Average Forecast Combination:** Esto consiste simplemente en tomar la media de las predicciones de los modelos individuales. (Diebold, 2017) presenta una defensa interesante de este método.
- **Regression Forecast Combination.** Esto consiste en simplemente hacer una regresión sin intercepto de los valores realizados sobre las predicciones de los modelos individuales hasta justo antes del momento de la predicción de interés y tomar los coeficientes resultantes como los *weights* para las predicciones individuales y generar las predicciones finales a partir de las predicciones de los modelos individuales y los *weights* anteriormente obtenidos. Al aplicar este método se omitió con dummies el período de la crisis del COVID-19.

4.2 Proceso de evaluación y diagnóstico de los modelos

Para evaluar la capacidad predictiva de estos modelos para cada una de estas variables se sigue un proceso de *Time Series Cross-Validation* con 60 interacciones, de modo que tenemos para cada horizonte de predicción (de 1 a 6 meses en nuestro caso) 60 errores de predicción. Véase (Diebold, 2017) o (Trevor Hastie y Friedman, 2017). Una vez realizado este proceso para todos los modelos queremos elegir el modelo que dé la mejor predicción puntual y cumpla con ciertos criterios de consistencia. A los modelos considerados se le

aplicaron una serie de filtros para su diagnosis con este objeto. El primer filtro tiene como objetivo evitar un sesgo pronunciado en el modelo con errores en la muestra y fuera de la muestra muy lejanos de cero en una dirección. Este es un paso elemental ya que un modelo con un sesgo pronunciado, aunque tenga poquísima varianza, sigue siendo un mal modelo ya que sus predicciones no son certeras. Esto se puede ver tanto gráficamente como cuantitativamente. Para verlo cuantitativamente se hace una regresión del error de predicción sobre un intercepto. Si el p-value del intercepto es cero, tomando en cuenta la precisión computacional, entonces el sesgo es pronunciado.

El segundo filtro procura determinar si los modelos sufren de sobreajuste (*overfitting*). Es común en los procesos de generación de predicciones que los modelos describen con mucha fidelidad la data pasada pero comparativamente tienen poca capacidad de anticiparse al futuro. Esta es una propiedad indeseable de un modelo predictivo. En nuestro caso detectamos sobreajuste (*overfitting*) gráficamente, observando si hay una gran diferencia entre qué tan cerca están las predicciones del modelo respecto al valor realizado dentro de la muestra (*in-sample*) y fuera de la muestra (*out-of-sample*). Una señal de que hay un problema de sobreajuste (*overfitting*) cuantitativamente es si el p-value es cero, a precisión numérica, en un test de igualdad de varianza.

El tercer filtro son tests formales de optimalidad de predicciones. Se aplicaron tres tests. El primero evalúa si el error de predicción a un mes sigue un proceso de ruido blanco. El segundo es el test de sesgo¹ y el tercero fue el test de regresión de Mincer-Zarnowitz. Estos tres tests devienen de lo que se llama el principio de impredecibilidad (*unforecastability principle*, en inglés), que establece que el error de predicción no debe de ser predecible si las predicciones usan la información disponible de manera óptima. Para más detalles véase (Diebold, 2017). La importancia de estos tests es que los mismos indican si el modelo usa de una manera efectiva la información disponible. En principio, si un modelo no pasa los tests está dejando de usar información que podría mejorar el rendimiento estadístico del modelo.

El cuarto y último filtro concierne a las bandas de predicción. La motivación de este filtro es que nos interesa no solo una predicción puntual, si no también una medida de su riesgo, que nos indique con qué seguridad el valor realizado cae en un rango alrededor de

¹La revisión para sesgo se repite. Esto se debe a que si un modelo tiene algo de sesgo (estadísticamente, como se verifica en el tercer filtro) puede aún así terminar siendo el mejor modelo, pero si este sesgo es muy pronunciado (como se verifica en el primer filtro) siempre será un mal modelo.

la predicción puntual con una cierta probabilidad. Se descartaron los modelos que en un excesivo o insuficiente porcentaje las observaciones cayeran dentro de las bandas ya que esto apunta a que la medida del riesgo de la predicción no es estadísticamente consistente. Para implementar este filtro se utilizó el test de Kolmogorov-Smirnoff comparando la distribución de los hit con una distribución de Bernoulli con el parámetro apropiado. Esto es lo que en inglés se llama *unconditional coverage*, que quiere decir que en el largo plazo las realizaciones caen dentro de las bandas en la proporción correcta. Este test se hizo para el caso de las bandas correspondientes a dos desviaciones estándar del error de predicción.²

Además del uso de la data real, se utilizó data sintética con el objetivo de reforzar la validación del modelo y asegurarnos de que los resultados no son dependientes de un dataset particular. Véase (López de Prado, 2019). Dicha data sintética fue creada siguiendo los siguientes pasos:

- Se le hace una transformación a la data para inducir estacionariedad
- Se divide la data en bloques para conservar la estructura de autocorrelación
- Se muestrean los bloques con reemplazo
- Se hace la transformación inversa para convertir la data en nivel

La decisión última de la elección del modelo para cada variable se hace en base a la distribución del error de predicción producto de la *Time Series Cross-Validation* y a los filtros antes mencionados.

²También se verifica por *conditional coverage*, que se puede interpretar como que en el corto plazo las realizaciones también caen dentro de las bandas en la proporción adecuada. Si se da esto último, tenemos que el hit de las bandas tiene una estructura de dependencia del mismo orden que el horizonte de predicción menos uno. Véase (Diebold, 2017) para más detalles.

5. Resultados

En esta sección nuestra meta es comparar los modelos explicados más arriba con miras a seleccionar para cada una de las variables consideradas los mejores modelos predictivos. Para comparar los modelos se utilizaron los parámetros de la distribución del error de predicción (media, desviación estándar, rango, mediana, cuartiles), los filtros anteriormente mencionados y recursos gráficos que serán mostrados más abajo. Analizaremos los resultados variable por variable, comenzando con los Cotizantes a las AFP. Véase los detalles en el Anexo.

5.1 Cotizantes a las AFP

Esta variable tiene tan solo 236 observaciones y gráficamente ya es sencillo de ver que no es estacionaria, ya que tiene una tendencia positiva bien marcada. Tests formales de estacionariedad confirman esto. Los tests utilizados fueron el test Augmented Dickey-Fuller, el test Phillip-Perron y el test KPSS. Véase (Hamilton, 1994). Esto indica que en el Box-Jenkins SARIMA debemos de diferenciar la data al menos una vez para tener un modelo válido mediante esta metodología. Estos mismos tests indican que la diferencia intermensual sí es estacionaria. Dicho esto, el componente estacional no es fácil de detectar a la vista. Para detectar este componente se utilizó la Función de Autocorrelación (ACF, por sus siglas en inglés) sobre la diferencia intermensual de la serie que sugiere estacionalidad de ciclo anual, ya que la autocorrelación a doce meses es significativa. Otra característica de la serie es que tiene un shock pronunciado provocado por la crisis del COVID-19, lo cual en principio dificulta su predicción.

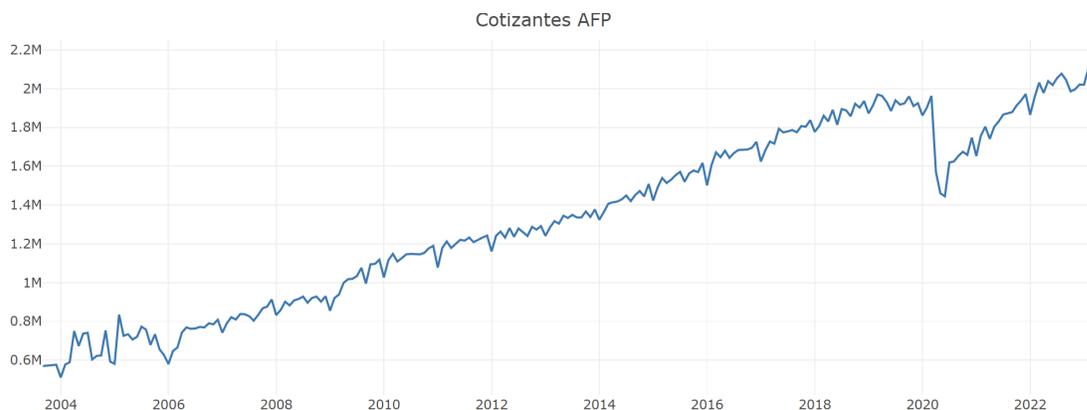


Figura 1. Cotizantes AFP, serie completa

El SARIMA Box-Jenkins finalmente utilizado para esta serie es un $(2,1,1) \times (1,1,0)$. Esta configuración captura bien la estructura de autocorrelación de la data como se puede apreciar del test de Box-Pierce sobre los residuos y de la ACF y la Función de Autocorrelación Parcial (PACF, por sus siglas en inglés) sobre los residuos del modelo estimado sobre el training set. Esto indica que el modelo representa la serie correctamente. Véase los detalles en el Anexo ³. Para el Minimum AIC ETS se eligió un modelo con tendencia, estacionalidad y residuo, ya que según lo mencionado anteriormente la serie parece tener estos tres componentes. En cuanto al Grid ARIMA, se eligió el siguiente grid: $p=0:5$, $d=0:2$ y $q=0:5$. Se eligió en el grid un máximo para el orden p y q de 5 para evitar considerar modelos que padezcan de overfitting, y un máximo de d igual a 2 porque para variables económicas cuando se diferencian con diferencia regular más de dos veces usualmente lo que queda es ruido, y por lo tanto lo que queda no tiene dinámica de media condicional. El modelo para este grid que dió mejores resultados fue un ARIMA $(4,2,4)$. En cuanto al Grid ETS se eligió el siguiente grid: $\alpha=0:0.1:1$, $\beta=0:0.1:1$, $\gamma=0:0.1:1$, siendo el modelo que dió mejores resultados un ETS $\alpha=0.7$, $\beta=0.1$, $\gamma=0.1$. Se eligió este grid para considerar modelos desde una mínima ponderación del pasado lejano a máxima ponderación.

Modelo	Configuración de los parámetros
Box-Jenkins SARIMA	SARIMA(2,1,1)x(1,1,0)
ETS	Minimum AIC (Aditivo con tendencia, estacionalidad y residuo)
Grid/Best ARIMA	ARIMA (4,2,4)
Grid/Best ETS	Alpha=0.7, Beta=0.1, Gamma=0.1
Average Forecast Combination	Media de las predicciones de los modelos anteriores
Regression Combination	Regresión sin intercepto de la predicción de los modelos anteriores sobre el valor realizado

Tabla 2: Modelos para Cotizantes a las AFP

Una vez estimados los modelos para el training set se evaluó su poder de predicción con un proceso de *Time Series Cross-Validation* y luego se les hizo una diagnosis a cada uno de ellos para su validación como mencionamos más arriba al hablar de los filtros. Todos los modelos pasaron los filtros del Sesgo (*Bias*) Pronunciado, del Sobreajuste (*Overfitting*) y de las Bandas. Sin embargo, solo pasaron uno de los 3 tests de optimalidad. Dicho esto, el modelo individual que da las predicciones más precisas en el test set es el Grid ETS tal y como se puede deducir de los parámetros de la distribución de los errores de predicción. Este es el modelo individual que consideramos tiene mejor rendimiento. Los resultados con la data sintética confirman lo anterior. En cuanto a la combinación de predicciones, ambas superaron en performance a los modelos individuales, siendo la *regression forecast combination*

³Figuras 12 a 21 y Tablas 24 a 31

la combinación de menor *Mean Square Error*⁴.

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
Box-Jenkins SARIMA	Si	Si	1	Si
Minimum AIC ETS	Si	Si	1	Si
Grid/Best ARIMA	Si	Si	2	Si
Grid/Best ETS	Si	Si	1	Si
Average Forecast Combination	Si	Si	2	Si
Regression Combination	Si	Si	1	Si

Tabla 3: Filtros para modelos de Cotizantes AFP

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	1,892	-3,458	19,673	-14,800	62,995	6,153
sd	134,197	139,101	134,611	135,483	91,329	156,512
percentil 0 %	-528,759	-552,158	-499,087	-544,997	-92,343	-532,773
25 %	-32,477	-40,074	-5,501	-38,868	10,285	-52,184
50 %	15,985	13,883	33,832	8,343	47,727	5,268
75 %	63,618	54,082	68,560	38,980	96,772	58,642
100 %	459,742	483,088	598,228	538,091	542,694	380,327

Tabla 4: Parámetros de los errores de predicción de los modelos para Cotizante AFP



Figura 2. Cotizantes AFP: predicción de uno a seis meses (step 1 a step 6) y valor realizado

⁴Al igual que los demás modelos, este supera el test de las bandas de *unconditional coverage*. Adicionalmente, este modelo es el único que supera el test de *conditional coverage*

También es interesante destacar el efecto de la crisis del COVID-19 sobre la predictibilidad de la variable. Luego del inicio de la crisis del COVID-19 por unos meses todos los modelos pierden poder de predicción. Sin embargo, el poder predictivo del SARIMA se ve afectado hasta el final de la muestra mientras los demás modelos vuelven a la normalidad en pocos meses. Esto se puede deber a la dificultad que puede presentar el SARIMA para capturar la estacionalidad de frecuencia anual, por lo que confunde parte del shock como si fuera un movimiento del componente estacional.

5.2 *Indice Mensual de Actividad Económica*

Esta variable inicia en enero de 2007 para un total de tan solo 194 observaciones. Con tan pocas observaciones, lo idóneo es trabajar con modelos sencillos que necesiten poca data para ser confiables. Para esta variable trabajamos con 4 modelos individuales. Esta serie no es estacionaria como se puede ver más abajo en la gráfica y como señalan los tests de estacionariedad.

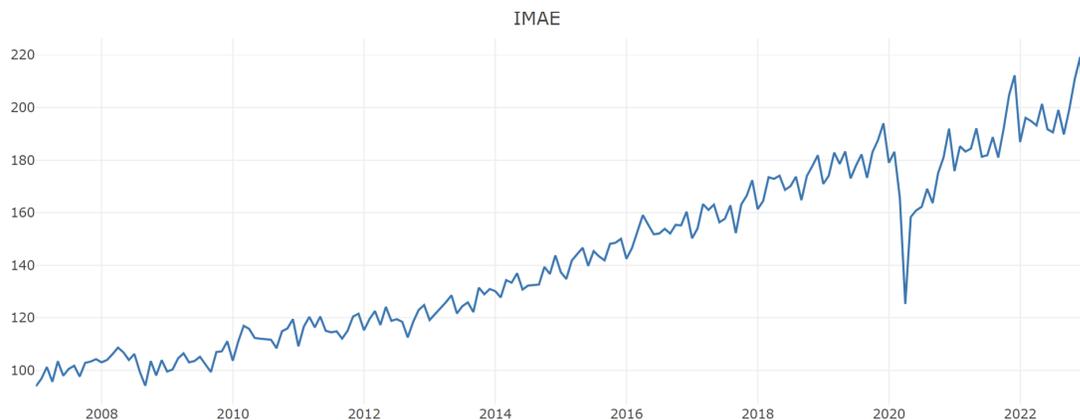


Figura 3. Indice Mensual de Actividad Económica, serie completa

En vista de que un simple Naive Estacional parecía prometedor, trabajamos con lo que dimos en llamar un *Double Naive*, que consiste simplemente primero en predecir con el rezago de doce meses antes y sumarle el último residuo resultante. Esto es equivalente a un $SARIMA(0,1,0) \times (0,1,0)$. Este modelo sencillo no resultó del todo satisfactorio ya que los residuos in-sample están altamente correlacionados como lo indica el test Box-Pierce y la ACF y la PACF sugiere que está sobrediferenciado. Debido a esto se intentó con un $SARIMA(3,0,0) \times (0,1,0)$ que tuvo una mejor diagnosis logrando pasar el test Box-Pierce. Para esta variable tenemos además un Grid/Best ARIMA y un *Direct Forecast Regression*.

El Grid es el mismo que para la serie de Cotizantes a las AFP y el Grid/Best ARIMA finalmente elegido fue un Arima(5,2,5). Véanse los detalles en el Anexo⁵.

Modelo	Configuración de los parámetros
Grid/Best ARIMA	ARIMA(0,2,3)
Box-Jenkins SARIMA	SARIMA(3,0,0)(0,1,0)
Double Naive	Equivalente a SARIMA(0,1,0)(0,1,0)
Direct Forecast Regression	Regresión con la última observación disponible
Average Forecast Combination	Media de SARIMA, Double Naive, Direct Forecast Regression and Best ARIMA

Tabla 5: Modelos para Índice Mensual de Actividad Económica (IMAE)

En cuanto a la diagnóstico, con excepción del Grid/Best ARIMA, los modelos pasan todos los filtros de la diagnosis menos los tests de optimalidad. El Grid/Best ARIMA los pasa todos⁶.

Modelos	Filtro 1: Bias Pronunciado	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit bandas
Best ARIMA	Si	Si	Si	Si
SARIMA	Si	Si	2	Si
Double Naive	Si	Si	2	Si
Direct Forecast Regression	Si	Si	2	Si
Average Forecast Combination	Si	Si	2	Si

Tabla 6: Filtros para los modelos de IMAE

Para esta variable la crisis del COVID también presentó dificultades. Solo el Grid ARIMA fue capaz de recuperarse en poco tiempo.



Figura 4. Índice Mensual de Actividad Económica: predicción de uno a seis meses y valor realizado

⁵Figuras 22 a 28 y Tablas 32 a 39

⁶El Grid/Best ARIMA pasa también el test de *conditional coverage*

Por estas razones el Grid/Best ARIMA es el modelo elegido, a pesar de que el *Average Forecast Combination* fue el método con predicción puntual más precisa tanto en la data real como en la data sintética.

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
media	0.14	0.55	-0.01	0.05	0.31
sd	5.70	5.25	5.73	8.33	4.94
percentil 0 %	-63.69	-63.32	-65.4	-71.52	-63.93
25 %	-2.55	-1.15	-1.8	-3.83	-1.18
50 %	0.47	0.44	0	0.34	0.24
75 %	3.53	2.53	2.3	4.41	2.20
100 %	27.73	63.94	67.1	46.76	51.97

Tabla 7: Parámetros de la distribución de los errores de predicción para Índice Mensual de Actividad Económica (IMAE)

5.3 Remesas

Para esta variable se realizó el mismo ejercicio que para la anterior. De entrada se consideraron un conjunto de modelos, se hizo con ellos *Time Series Cross-Validation*, se utilizaron los errores de predicción para evaluar la performance y se les hizo la diagnosis. A partir de estos dos últimos pasos se eligió el modelo a utilizar. La data sintética sirvió para reforzar la conclusión.

Esta es nuestra serie más corta con 159 observaciones iniciando en enero del 2010. Igual que las series anteriores, esta también tiene un obvio componente de tendencia que se puede apreciar gráficamente y utilizando tests estándares como los vistos anteriormente. El componente estacional no es del todo obvio gráficamente, pero es sumamente patente al observar el patrón de la ACF y la PACF de la diferencia intermensual, que es una variable estacionaria según los tests⁷. Igual que en el caso de las series anteriores hay un gran shock debido a la crisis del COVID-19.

⁷Figuras 29 a 38 y Tablas 40 a 47

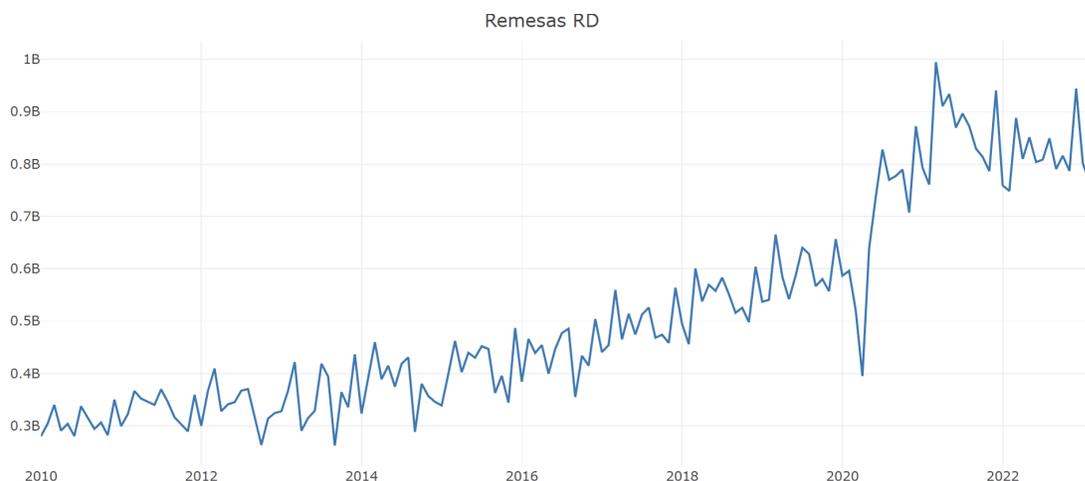


Figura 5. Remesas, serie completa

El Box-Jenkins ARIMA identificado fue un SARIMA(0,1,1)x(0,1,1) el cuál paso la diagnosis que se hace para esta metodología con parámetros altamente significativos y ninguna evidencia de que haya dejado sin modelar alguna estructura de autocorrelación importante como indica el Box-Pierce test de los residuos y la ACF y la PACF de los residuos. Como el proceso de las Remesas parece tener los tres componentes de tendencia, estacionalidad y residuo se estimó un Minimum AIC ETS con los tres componentes. El Grid/Best ARIMA y el Grid/Best ETS se identificaron de la misma manera que para los Cotizantes AFP. El rendimiento en el *Time Series Cross-Validation* está muy cercana entre modelos.

Modelo	Configuración de los parámetros
Box-Jenkins SARIMA	SARIMA(0,1,1)x(0,1,1)
ETS	Minimum AIC (con tendencia, estacionalidad y residuo)
Grid/Best ARIMA	ARIMA(2,2,5)
Grid/Best ETS	alpha=0.2,beta=0.1,gamma=0.1
Average Forecast Combination	Media de la predicción de los 4 modelos previos
Regression Combination	Regresión con la predicción de los primeros 4 modelos

Tabla 8: Modelos para Remesas

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast	SARIMA
media	14,953,116	4,024,223	24,765,830	17,629,122	46,774,333	13,393,288
sd	85,069,017	96,755,964	87,595,586	83,472,667	93,921,753	86,148,246
percentil 0 %	-236,804,757	-255,122,878	-231,089,541	-236,252,931	-128,536,937	-229,582,483
25 %	-23,772,343	-48,515,843	-20,104,423	-22,810,854	-23,832,399	-29,377,390
50 %	9,750,355	-9,778,154	18,601,126	11,049,618	38,183,650	11,903,574
75 %	40,897,211	53,972,126	49,638,868	40,040,954	103,673,861	35,981,183
100 %	299,969,191	295,933,696	289,099,576	358,316,976	252,307,749	318,530,655

Tabla 9: Parámetros de la distribución de los errores de predicción de los modelos para Remesas

En cuanto a la diagnosis solo el Minimum AIC ETS pasó todos los filtros. Los otros modelos no pasaron uno de los tests de optimalidad y el *regression combination* no pasó ninguno de estos. Ya que el Minimum AIC ETS tuvo la mejor predicción puntual y la mejor diagnosis, este es el modelo elegido para esta variable.

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
SARIMA	Si	Si	2	Si
Minimum AIC ETS	Si	Si	Si	Si
Grid/Best ARIMA	Si	Si	2	Si
Grid/Best ETS	Si	Si	2	Si
Average Forecast Combination	Si	Si	2	Si
Regression Combination	Si	Si	0	Si

Tabla 10: Filtros para los modelos de Remesas

5.4 Crédito Privado en Moneda Nacional

Esta variable comienza en enero del 2007 con 196 observaciones. Al contrario de las variables anteriores no presenta un shock notable para el período de la crisis del COVID-19. Para esta variable se siguió el mismo proceso de identificación de los modelos en el training set, *Time Series Cross-Validation* y evaluación y diagnosis. Al contrario de las variables anteriores, para esta variable no hay ninguna evidencia de componente estacional. Esto es patente también en la ACF y la PACF de la diferencia intermensual de la variable. Por esta razón, en la identificación del Box-Jenkins SARIMA y el Minimum AIC ETS omitimos el componente estacional.

Cartera de Crédito Privada MN



Figura 6. Crédito Privado en Moneda Nacional en variación interanual, serie completa en variación interanual

El Box-Jenkins SARIMA identificado es un SARIMA $(1,2,1) \times (0,0,0)$. Esta configuración captura la estructura de autocorrelación de la data como es patente en la ACF y la PACF de los residuos del modelo y el Box-Pierce test⁸. El Minimum AIC ETS identificado es uno con solo tendencia y residuos modelando el nivel de la variable, ya que no hay evidencia de estacionalidad. Para el resto de modelos se siguió los mismos pasos que para las variables anteriores.

Modelo	Configuración de los parámetros
SARIMA	SARIMA(1,2,1)x(0,0,0)
ETS	Minimum AIC (Con solo tendencia y residuo)
Grid/Best ARIMA	ARIMA(4,2,2)
Grid/Best ETS	alpha=0.8,beta=0.1,gamma=0.1
Average Forecast Combination	Media de las predicciones de los modelos anteriores
Regression Combination	Regresión sin intercepto de las predicciones de los primeros 4 modelos sobre las realizaciones

Tabla 11: Modelos para Crédito Privado en Moneda Nacional

⁸Figuras 39 a 47 y Tablas 48 a 58

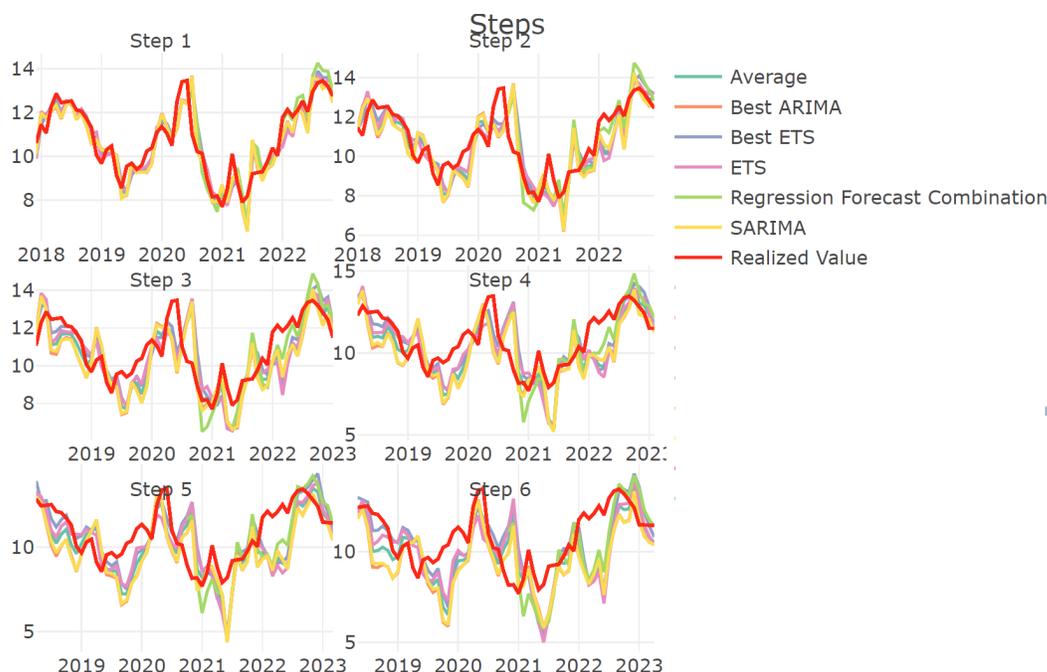


Figura 7. Predicciones de uno a 6 meses (step 1 a step 6) y valor realizado en variación interanual, Crédito

Para esta variable, solo el *Regression Forecast Combination* no pasó toda la diagnosis. Dado esto último, como el Grid/Best ETS tuvo el menor *Mean Square Error* fue el modelo elegido.

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
SARIMA	Si	Si	Si	Si
ETS	Si	Si	Si	Si
Best ARIMA	Si	Si	Si	Si
Best ETS	Si	Si	Si	Si
Average Forecast Combination	Si	Si	Si	Si
Regression Combination	Si	Si	2	Si

Tabla 12: Filtros para los modelos de Crédito

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	4,802,963,509	6,544,584,473	2,215,448,287	3,927,974,571	2,201,686,867	6,523,846,704
sd	12,952,602,222	13,159,277,695	13,522,179,091	13,726,669,581	15,449,264,885	13,093,672,109
percentil 0 %	-39,772,443,000	-35,168,906,132	-45,246,298,246	-47,894,341,922	-37,061,553,702	-34,686,466,547
25 %	-3,097,724,877	-1,434,578,646	-5,381,905,103	-3,653,908,594	-7,502,556,649	-1,228,627,696
50 %	3,720,487,961	5,865,930,723	913,131,487	2,393,666,451	2,016,243,163	5,850,485,901
75 %	11,956,179,085	14,297,187,630	8,184,231,428	10,992,718,071	12,991,161,552	14,100,603,570
100 %	51,841,208,782	51,287,873,159	48,241,123,270	56,558,432,451	39,406,916,758	51,277,406,249

Tabla 13: Parámetros de la distribución de los errores de los modelos en nivel, nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.48	0.66	0.21	0.38	0.22	0.662
sd	1.29	1.34	1.32	1.34	1.45	1.33
percentil 0 %	-3.99	-3.57	-4.53	-4.75	-3.73	-3.52
25 %	-0.33	-0.14	-0.56	-0.38	-0.67	-0.15
50 %	0.40	0.61	0.09	0.28	0.18	0.64
75 %	1.24	1.50	0.90	1.13	1.25	1.48
100 %	4.48	4.51	4.16	4.89	3.83	4.43

Tabla 14: Parámetros de la distribución de los errores de los modelos en variación interanual, modelando las variables en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	-0.03	0.01	-0.01	-0.07	-1.20	-0.05
sd	1.55	1.50	1.74	1.61	21.07	1.58
percentil 0 %	-6.04	-5.36	-5.82	-7.00	-65.67	-6.637545012
25 %	-0.90	-0.82	-1.10	-0.99	-8.33	-0.94
50 %	0.15	0.04	0.38	0.01	1.03	0.02
75 %	1.03	1.04	1.25	1.01	10.47	1.05
100 %	2.94	3.07	3.09	3.34	60.14	3.26

Tabla 15: Parámetros de la distribución de los errores de los modelos en variación interanual, modelando las variables directamente en variación interanual

Esta variable fue modelizada en nivel y luego se transformaron los resultados de los modelos a variación interanual, ya que los resultados en variación interanual son de mayor interés. Para esta variable también se realizó la modelización directamente con la data transformada a variación interanual. Los resultados sugieren que para esta variable es mejor modelizar la variable en niveles y luego transformar los resultados de los modelos a variación interanual que modelizar la variación interanual directamente.

5.5 IPC

Esta serie comienza en enero de 1984 con 471 observaciones. Al igual que la variable de Crédito, el efecto de la crisis del COVID-19, no es tan obvio en esta variable aunque se nota su efecto deflacionario. Se siguió con esta variable el mismo proceso señalado anteriormente.

Esta variable resultó relativamente predecible. Sin embargo, el Box-Jenkins SARI-MA identificado no se pudo deshacer de toda la estructura de autocorrelación según la

ACF, aunque los residuos pasaron el Box-Pierce test⁹. El SARIMA elegido fue un SARIMA(1,1,0)x(0,2,0). El Minimum AIC ETS estimado para el nivel cuenta con los tres componentes de tendencia, estacionalidad y residuo, a partir de la evidencia de estos componentes de los tests de estacionariedad y la ACF y la PACF de la diferencia de la variable. El resto de los modelos se identificaron de la misma manera que para las variables anteriores.

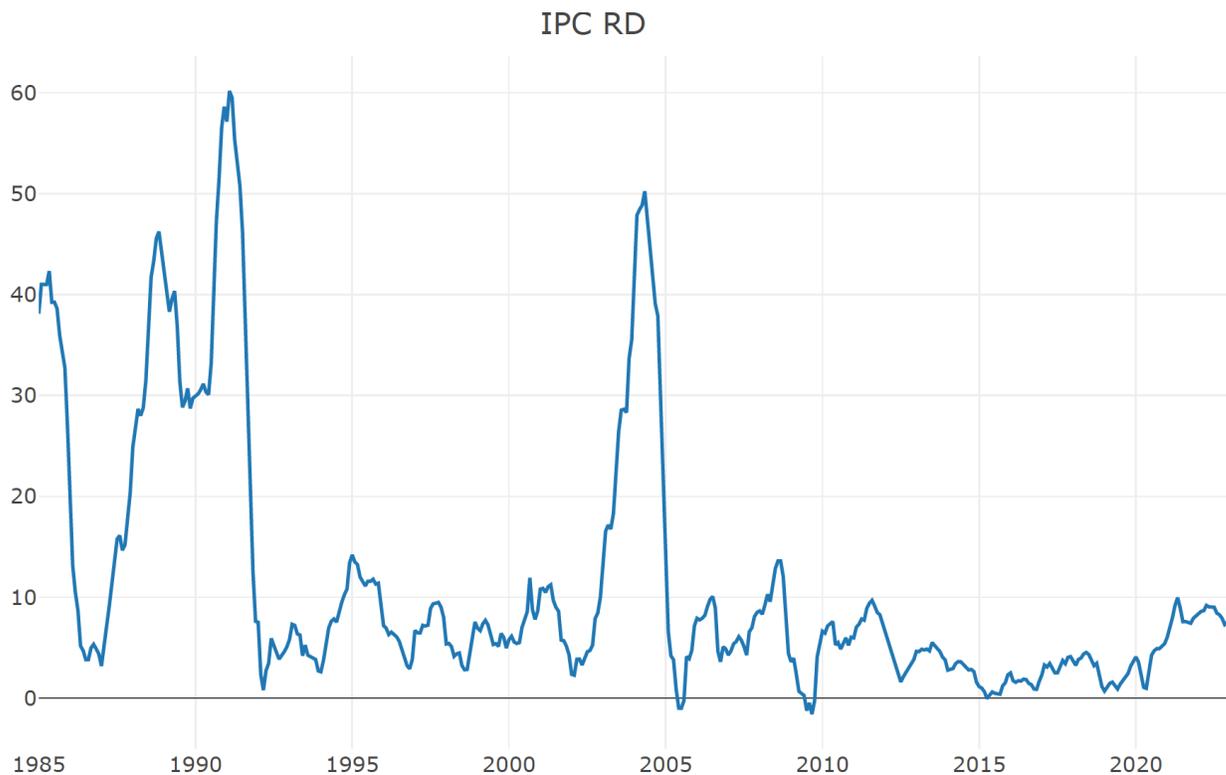


Figura 8. IPC en variación interanual, serie completa

Modelo	Configuración de los parámetros
Grid/Best ARIMA	ARIMA(1,2,1)
SARIMA	SARIMA(1,1,0)(0,2,0)
ETS	Minimum AIC (con tendencia, estacionalidad y residuo)
Grid/Best ETS	ETS (alpha=0.4,beta=0.1,gamma=0.5)
Average Forecast Combination	Media de las predicciones de los primeros 4 modelos
Regression Forecast Combination	Regresión de las predicciones de los primeros 4 modelos sobre las realizaciones

Tabla 16: Modelos para IPC

La predictibilidad de la serie se puede ver en los parámetros de la distribución de los

⁹Figuras 48 a 57 y Tablas 59 a 68

errores de cada modelo.

	Average Combination	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.43	0.45	0.63	0.77	0.75	-0.12
sd	1.29	1.25	1.30	1.37	1.42	2.61
percentil 0 %	-2.97	-2.61	-2.42	-2.31	-1.57	-8.37
25 %	-0.30	-0.29	-0.23	-0.09	-0.20	-1.64
50 %	0.26	0.31	0.51	0.47	0.55	-0.21
75 %	1.03	0.96	1.22	1.38	1.59	1.35
100 %	5.65	5.57	6.37	7.22	5.43	7.71

Tabla 17: Parámetros de la distribución de los errores de predicción de los modelos para IPC en nivel

	Average Combination	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.41	0.41	0.59	0.72	0.73	-0.07
sd	1.27	1.21	1.27	1.33	1.34	2.49
percentil 0 %	-3.00	-2.64	-2.44	-2.34	-1.29	-7.25
25 %	-0.30	-0.28	-0.22	-0.08	-0.18	-1.49
50 %	0.25	0.31	0.48	0.43	0.51	-0.21
75 %	1.01	0.91	1.19	1.31	1.48	1.30
100 %	5.62	5.55	6.33	7.25	5.37	7.41

Tabla 18: Parámetros de la distribución de los errores de predicción de los modelos para IPC en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	-0.03	-0.13	0.11	0.06	0.71	-0.15
sd	1.44	1.50	1.65	1.98	2.16	1.35
percentil 0 %	-3.69	-4.23	-3.93	-5.42	-4.66	-4.18
25 %	-0.88	-1.09	-1.03	-0.94	-0.53	-0.85
50 %	0.07	0.002	0.26	0.001	0.52	-0.10
75 %	0.76	0.60	1.08	1.03	1.62	0.49
100 %	4.73	4.30	4.37	7.87	7.36	4.79

Tabla 19: Parámetros de la distribución de los errores en variación interanual modelando directamente la variación interanual

En cuanto a la diagnosis, el único modelo en pasar todos los filtros es el Grid/Best ARIMA. En vista de que el Grid/Best ARIMA pasó toda la diagnosis y de que es el modelo con menor *Mean Square Error* este fue el modelo elegido.

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
Best ARIMA	Si	Si	Si	Si
SARIMA	Si	Si	2	Si
ETS	Si	Si	1	Si
Best ETS	Si	Si	1	Si
Average Forecast Combination	Si	Si	2	Si
Regression Forecast Combination	Si	Si	1	Si

Tabla 20: Filtros para los modelos del IPC en variación interanual

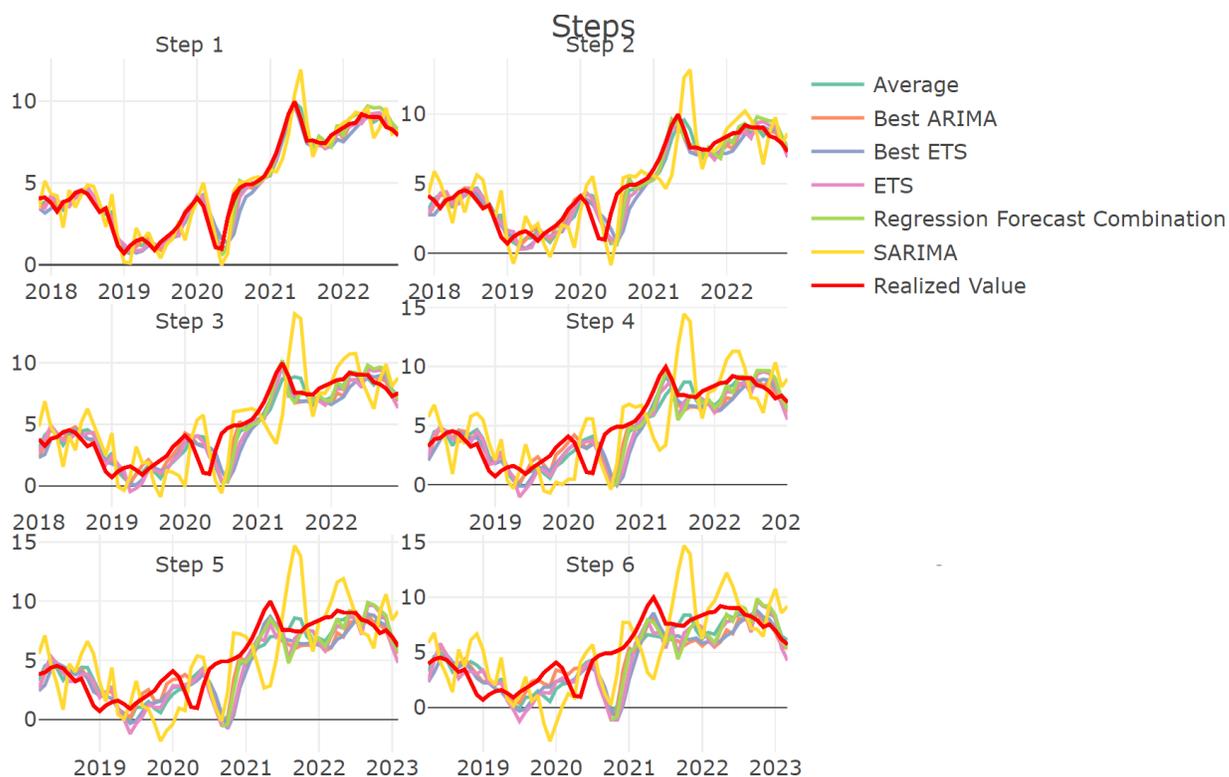


Figura 9. Predicción de 1 a 6 meses y valor realizado

Esta variable también fue modelizada en nivel y luego se transformaron los resultados de los modelos a variación interanual. Para esta variable también se modelizó la variación interanual directamente. Para esta variable también resultó que es mejor modelizar en nivel y después transformar los resultados a variación interanual que modelizar directamente la variación interanual.

5.6 Llegada de Turistas

Esta es nuestra serie más larga con 543 observaciones comenzando en enero de 1978. Es patente el shock que significó la crisis del COVID-19 pasando de alrededor de 600 mil turistas a principios del 2019 a prácticamente 0 en abril del 2020. Observando la serie tan bien es muy obvio el importante componente estacional de la serie y su tendencia. Así vemos que en niveles la variable no pasa los tests de estacionariedad, dada su tendencia, pero si pasa los tests en diferencias. El fuerte componente estacional se refleja en la ACF y PACF de la variable en diferencia intermensual. Véase el Anexo¹⁰.

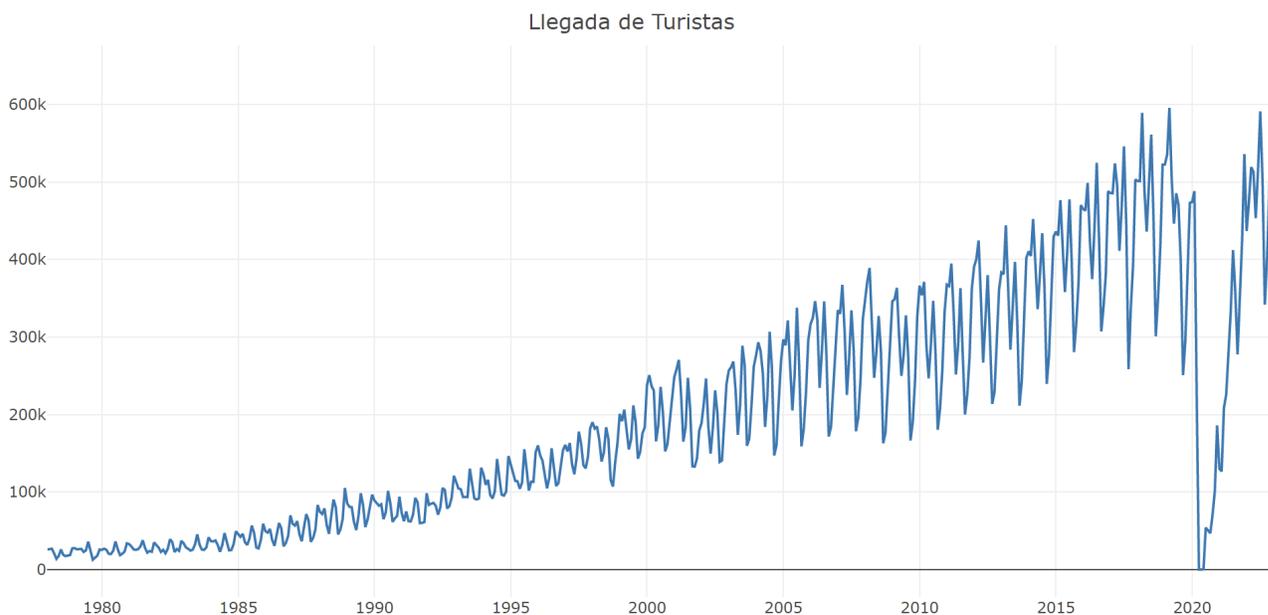


Figura 10. Turistas, serie completa

El Box-Jenkins SARIMA identificado fue un SARIMA $(1,1,1) \times (1,1,1)$. Dicho esto el modelo no logra deshacerse de toda la estructura de autocorrelación como se puede ver en la ACF y PACF de los residuos. Otros SARIMAs con una configuración razonable tuvieron este defecto. Dada la evidencia de que la serie tiene componente de tendencia y de estacionalidad obvios el Minimum AIC ETS fue un con tendencia, estacionalidad y residuo. Los demás modelos se identificaron de la misma manera que para las variables anteriores.

¹⁰Figuras 58 a 68 y Tablas 69 a 76

Modelo	Configuración de los parámetros
SARIMA	SARIMA(1,1,1)x(1,1,1)
ETS	Minimum AIC con tendencia, estacionalidad y residuo
Best ARIMA	ARIMA(5,1,5)
Best ETS	alpha=0.1,beta=0.1,gamma=0.4
Average Forecast Combination	Media de las predicciones de los modelos anteriores
Regression Combination	Regresión del valor realizado sobre las predicciones de los primeros 4 modelos

Tabla 21: Modelos para Llegada de Turistas

De todos los modelos el que tiene la predicción puntual de mayor precisión es el Minimum AIC ETS. Dicho esto, los modelos pasan solo 3 de los 4 filtros de la diagnosis, ya que ninguno logra pasar todos los tests de optimalidad. Por estas razones, para esta variable, el modelo elegido para predecir es el Minimum AIC ETS.

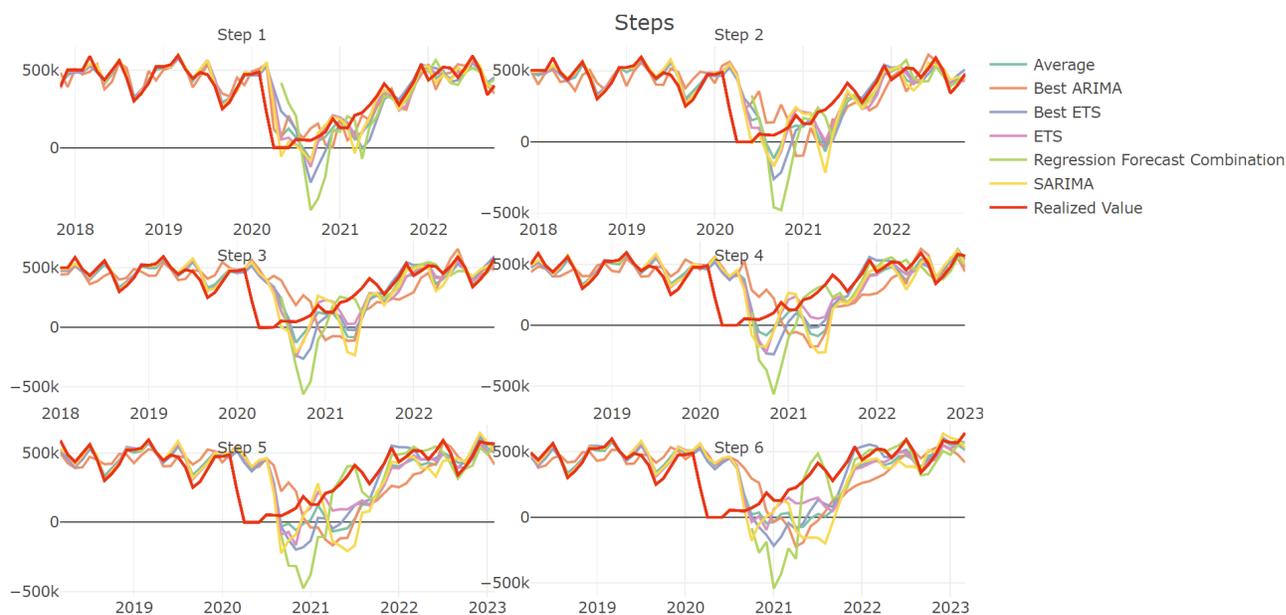


Figura 11. Turistas, Predicción de 1 a seis meses y valor realizado

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
media	13,588	1,247	13,016	7,874	8,931	1,560
sd	162,136	131,586	175,599	145,676	141,378	145,152
percentil 0 %	-468,914	-461,065	-488,746	-440,271	-461,922	-420,339
25 %	-29,711	-23,179	-72,578	-31,502	-28,928	-64,736
50 %	1,066	5,219	20,709	5,533	14,489	-1,958
75 %	60,588	57,374	104,784	52,744	64,402	75,079
100 %	580,395	296,827	464,619	366,564	387,206	422,118

Tabla 22: Parámetros de la distribución de los errores de predicción para Turistas

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
Box-Jenkins SARIMA	Si	Si	2	Si
Minimum AIC ETS	Si	Si	1	Si
Grid/Best ARIMA	Si	Si	2	Si
Grid/Best ETS	Si	Si	2	Si
Average Forecast Combination	Si	Si	2	Si
Regression Combination	Si	Si	1	Si

Tabla 23: Filtros para los modelos de Llegada de Turistas

6. Conclusión

Del ejercicio realizado se extraen básicamente 4 conclusiones. La primera es que las variables consideradas son relativamente predecibles ya que el tamaño típico del error de predicción es modesto respecto al tamaño de la variable. La segunda lección es que se debe de tener cuidado a la hora de usar un SARIMA con componente estacional en muestras pequeñas luego de un shock pronunciado, ya que el modelo confunde parte del shock como un movimiento estacional. Esto se nota con este modelo para todas las variables que tienen un shock pronunciado a causa de la crisis del COVID-19, del que dura mucho el modelo en recuperarse. La tercera conclusión es que se confirma lo que dice la literatura sobre combinaciones de predicciones, que los mismos suelen mejorar las predicciones puntuales. Para la mitad de las variables, alguna de las combinaciones mejoró la predicción puntual del mejor modelo individual. Como cuarta conclusión podemos mencionar que si queremos generar predicciones de variables que tenemos en nivel de su variación interanual, es recomendable modelizar tanto en nivel y transformar los resultados a interanual como modelizar directamente en interanual. Esto se debe a que modelizando en nivel podemos tener mejores resultados para la variación interanual. Dicho esto, esto es algo que se ha de examinar variable por variable.

Referencias

- Assimakopoulos, V., y Nikolopoulos, K. (2000). The theta model: a decomposition approach to forecasting. *International Journal of Forecasting*, 521-530.
- Atiya, A. F. (2020). Why does forecast combination work so well? *International Journal of Forecasting*, 36, 197-200.
- Bates, J., y Granger, C. W. J. (1969). The combination of forecasts. *Operational Research Quarterly*, 20(4), 451-468.
- Cirillo, P. (2013). Are your data really pareto distributed? *Physica A*, 392, 5947-5962. Descargado de <https://doi.org/10.1016/j.physa.2013.07.061>
- Cirillo, P., y Taleb, N. N. (2020). Tail risk of contagious diseases. *Nature Physics*, 16, 606-613.
- Cochrane, J. (2000). *Asset pricing*. Springer.
- Diebold, F. X. (2017). *Forecasting*. Department of Economics, University of Pennsylvania.
- Engle, R. F., y Granger, C. W. J. (1987). Co-integration and error correction: Representation, estimation and testing. *Econometrica*, 55, 251-276.
- Fildes, R., Goodwin, P., Lawrence, M., y Nikolopoulos, K. (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, 25, 3-23.
- Fildes, R., y Petropoulos, F. (2015). Simple versus complex selection rules for forecasting many time series. *Journal of Business Research*, 68, 1692-1701.
- Fontanari, A., Cirillo, P., y Oosterlee, C. W. (2018). From concentration profiles to concentration maps. new tools for the study of loss distributions. *Insurance: Mathematics and Economics*, 78, 13-29. Descargado de <https://doi.org/10.1016/j.insmatheco.2017.11.003>
- Gilliland, M. (2020). The value added by machine learning approaches in forecasting. *International Journal of Forecasting*, 36, 161-166.
- Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press.
- Hewamalage, H., Bergmeir, C., y Bandara, K. (2020). Recurrent neural networks for time series forecasting: Current status and future directions. *Working Paper*, 42-63.
- Hyndman, R. J. (2020). A brief history of forecasting competitions. *International Journal of Forecasting*. Descargado de <https://doi.org/10.1016/j.ijforecast.2019.03.015>
- Hyndman, R. J., y Asthanasopoulos, G. (2021). *Forecasting: Principles and practice*. Princeton University Press.

- Hyndman, R. J., y Kang, Y. (2022). Forecasts combinations. an over 50-year review. *International Journal of Forecasting*.
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., y Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18, 439-454.
- Ioannidisa, J. P., Cripps, S., y Tanner, M. A. (2020). Forecasting for covid-19 has failed. *International Journal of Forecasting*. Descargado de www.elsevier.com/locate/ijforecast
- Jimenez Polanco, M., y Ramírez Escoboza, M. (2015). Predicción de la actividad económica a partir de indicadores de las encuestas de opinión empresarial: Evidencia para república dominicana. *Consejo Monetario Centroamericano*.
- Johansen, S., y Juselius, K. (1990). Maximum likelihood estimation and inference on cointegration — with applications to the demand for money. *Oxford Bulletin of Economics and Statistics*, 52, 169-200.
- Juul, J. L., Græsbøll, K., Christiansen, L. E., y Lehmann, S. (2021). Fixed-time descriptive statistics underestimate extremes of epidemic curve ensembles. *Nature Physics*.
- Khosravi, A., Nahavandi, S., Creighton, D., y Atiya, A. F. (2011). Comprehensive review of neural network-based prediction intervals and new advances. *Transactions on Neural Networks*, 22, 1341-1357.
- Kostenko, A., y Hyndman, R. (2006). A note on the categorization of demand patterns. , 1-4.
- Lago, J., Ridder, F. D., y Schutter, B. D. (2018). Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221, 386-405.
- Lago, J., Ridder, F. D., Vrancx, P., y De Schuttera, B. (2018). Forecasting day-ahead electricity prices in europe: The importance of considering market integration. *Applied Energy*, 211, 890-903.
- Lutkepohl, H. (2005). *New introduction to multiple time series analysis*. Springer.
- López de Prado, M. (2019). *Advances in financial machine learning*. Springer.
- Makridakis, S., Bonnell, E., Clarke, S., Fildes, R., Gilliland, M., Hoover, J., y Tashman, L. (2020). The benefits of systematic forecasting for organizations: The ufo project. *The International Journal of Applied Forecasting*, 59, 45-55.
- Makridakis, S., y Hibon, M. (1987). Confidence intervals: An empirical investigation of the series in the m-competition. *International Journal of Forecasting*, 3, 489-508.

- Makridakis, S., Hyndman, R. J., y Petropoulos, F. (2019). Forecasting in social settings: The state of the art. *International Journal of Forecasting*.
- Makridakis, S., y Petropoulos, F. (2019). The m4 competition: Conclusions. *International Journal of Forecasting*.
- Montero-Manso, P., Athanasopoulos, G., Hyndman, R. J., y Talagala, T. S. (2020). Fforma: Feature-based forecast model averaging. *International Journal of Forecasting*, 36, 86-92.
- Montero-Manso, P., y Hyndman, R. J. (2021). Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 37, 1632-1653.
- Oreshkin, B. N., Carпов, D., Chapados, N., y Bengio, Y. (2020). N-beats: Neural basis expansion analysis for interpretable time series forecasting. *ICLR Conference*.
- Petropoulos, F., Hyndman, R. J., y Bergmeir, C. (2018). Exploring the sources of uncertainty: Why does bagging for time series forecasting work? *European Journal of Operational Research*, 268, 545-554.
- Ruoss, E., y Savioz, M. (2002). How accurate are gdp forecasts? an empirical study for switzerland. *SNB Quarterly Bulletin*, 42-63.
- Salinas, D., Flunkert, V., y Gasthaus, J. . (2019). Deep ar: Probabilistic forecasting with auto regressive recurrent networks. , *Amazon Research*.
- Semenoglou, A.-A., Spiliotis, E., Makridakis, S., y Assimakopoulos, V. (2021). Investigating the accuracy of cross-learning time series forecasting methods. *International Journal of Forecasting*, 37, 368-378.
- Sims, C. (1980). Macroeconomics and reality. *Econometrica*, 48, 1-48.
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 75-85. Descargado de <https://doi.org/10.1016/j.ijforecast.2019.03.017>
- Spiliotis, E. (2022). Decision trees for time-series forecasting.
- Taleb, N. N., Bar-Yam, Y., y Cirillo, P. (2020). On single point forecasts for fat-tailed variables. *International Journal of Forecasting*. Descargado de <https://doi.org/10.1016/j.ijforecast.2020.08.008>.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*, 16, 437-450.
- Trevor Hastie, R. T., y Friedman, J. (2017). *Elements of statistical learning*. Springer.
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look

into the future. *International Journal of Forecasting*, 30, 1030-1081.

Anexo

Resultados por variables

.0.1 Cotizantes AFP

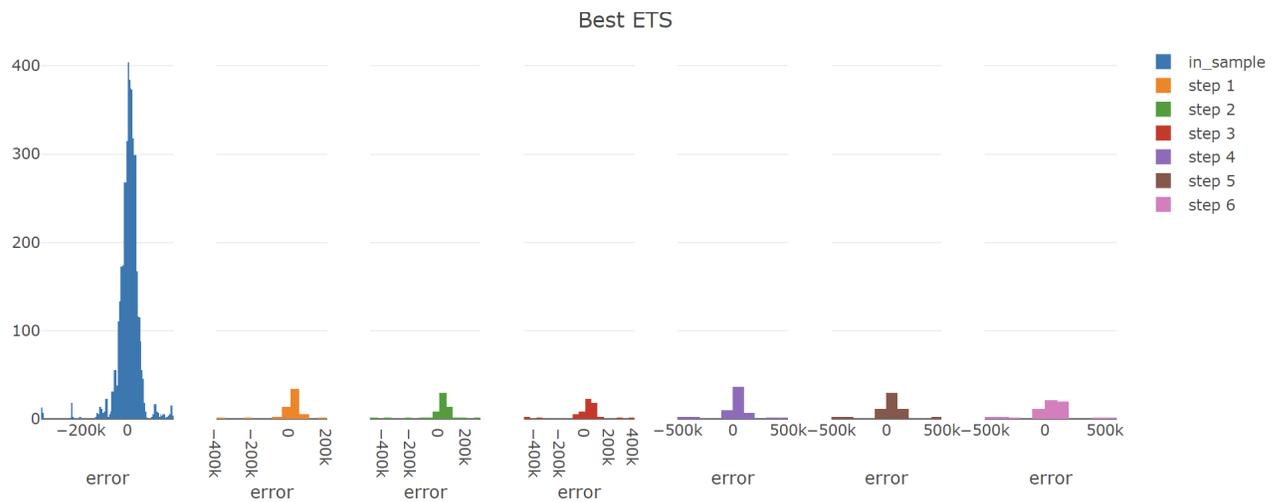


Figura 12. Residuos Best/Grid ETS para Cotizantes a las AFP

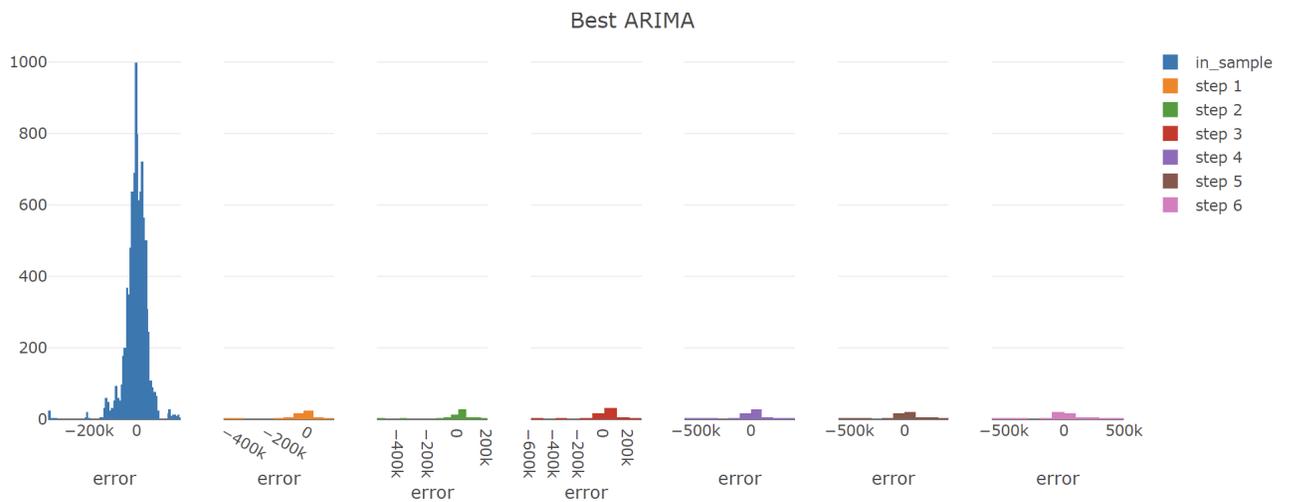


Figura 13. Residuos Best/Grid ARIMA para Cotizantes a las AFP

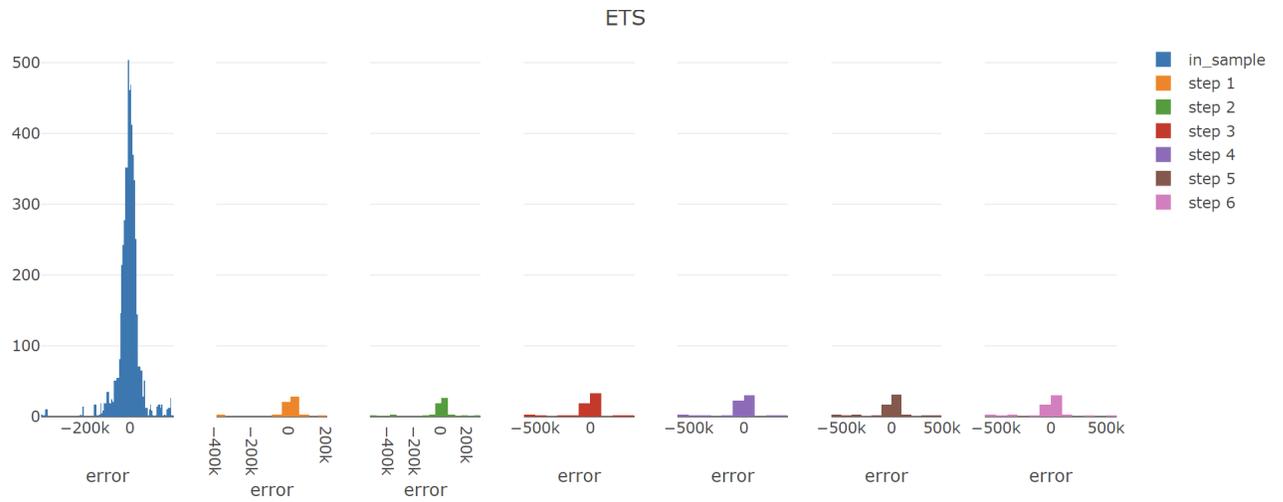


Figura 14. Residuos Minimum AIC ETS para Cotizantes a las AFP

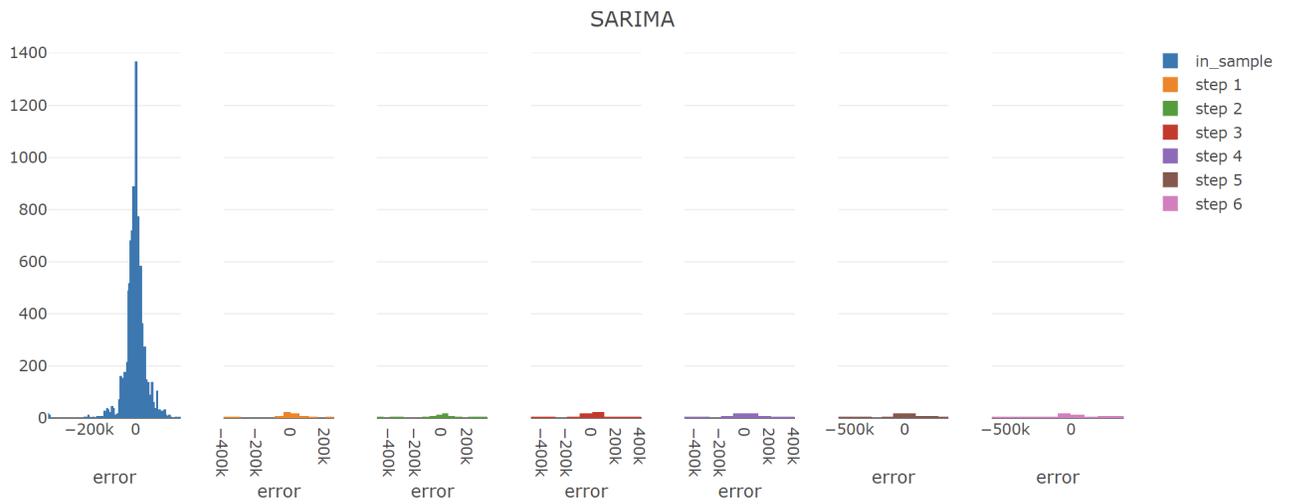


Figura 15. Residuos box-Jenkins SARIMA para Cotizantes a las AFP

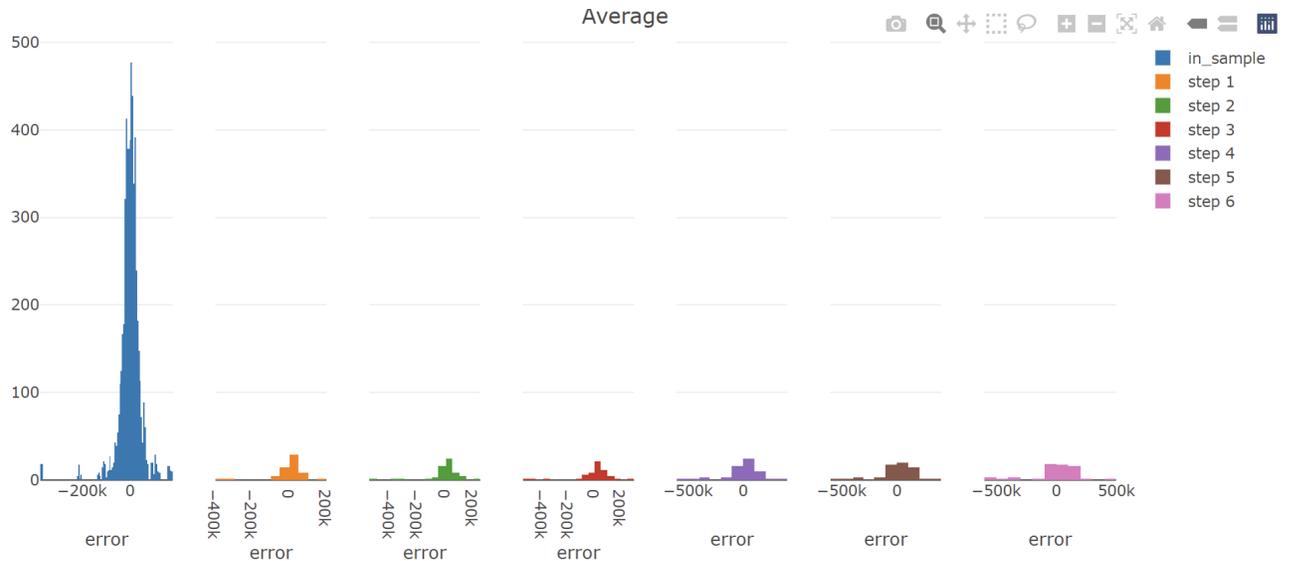


Figura 16. Residuos Average Combination para Cotizantes a las AFP

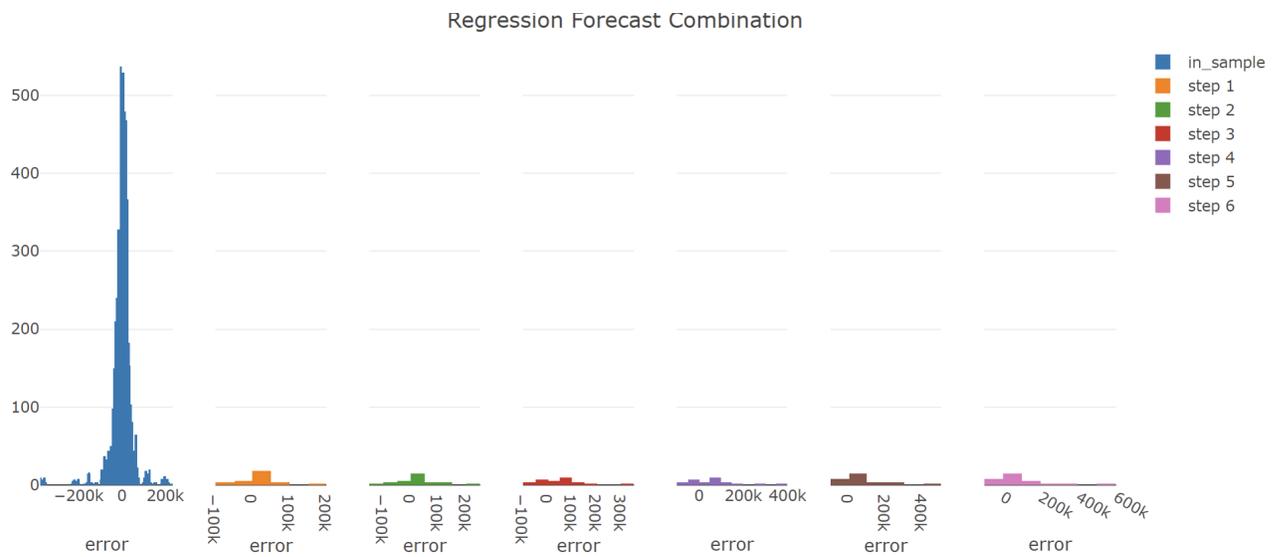


Figura 17. Residuos Regression Forecast Combination para Cotizantes a las AFP

ACF diferencia intermensual Cotizantes

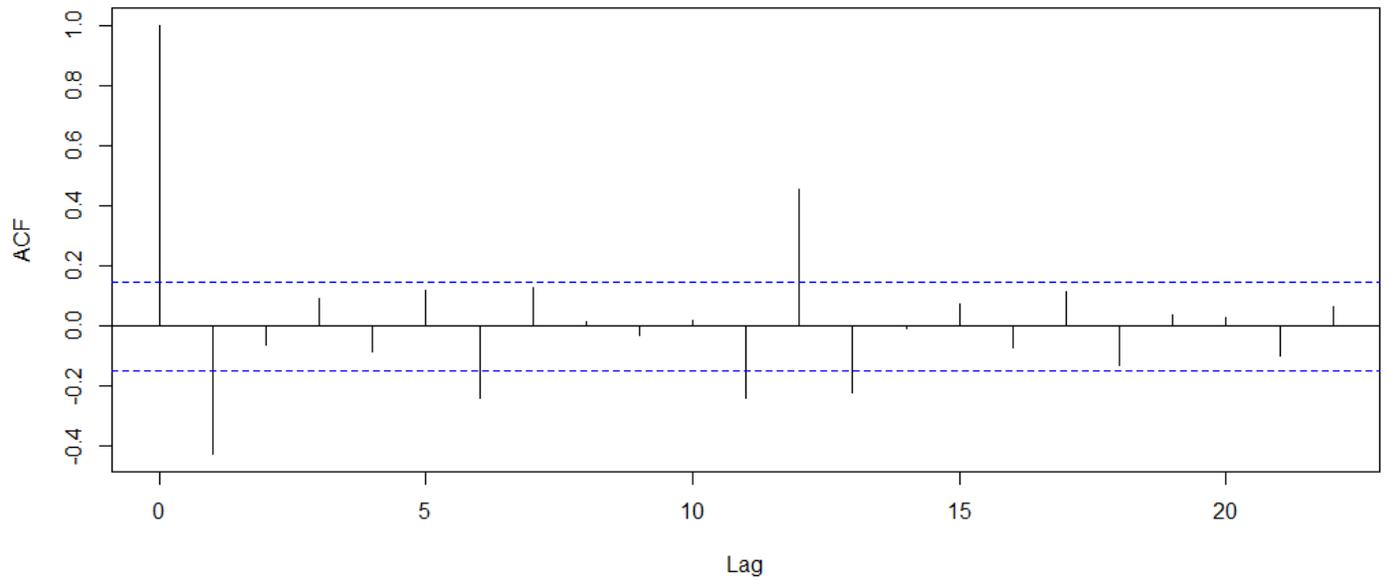


Figura 18. Cotizantes AFP: ACF de la diferencia intermensual de Cotizantes a las AFP.

PACF diferencia intermensual Cotizantes

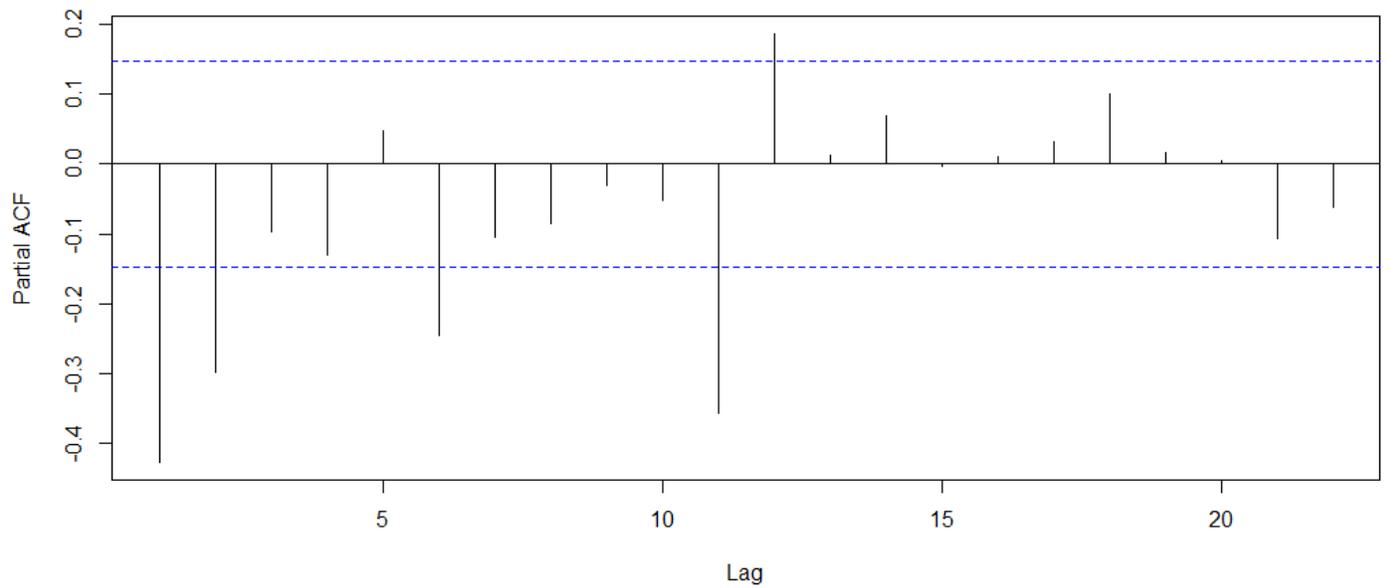


Figura 19. Cotizantes AFP: PACF de la diferencia intermensual de Cotizantes a las AFP.

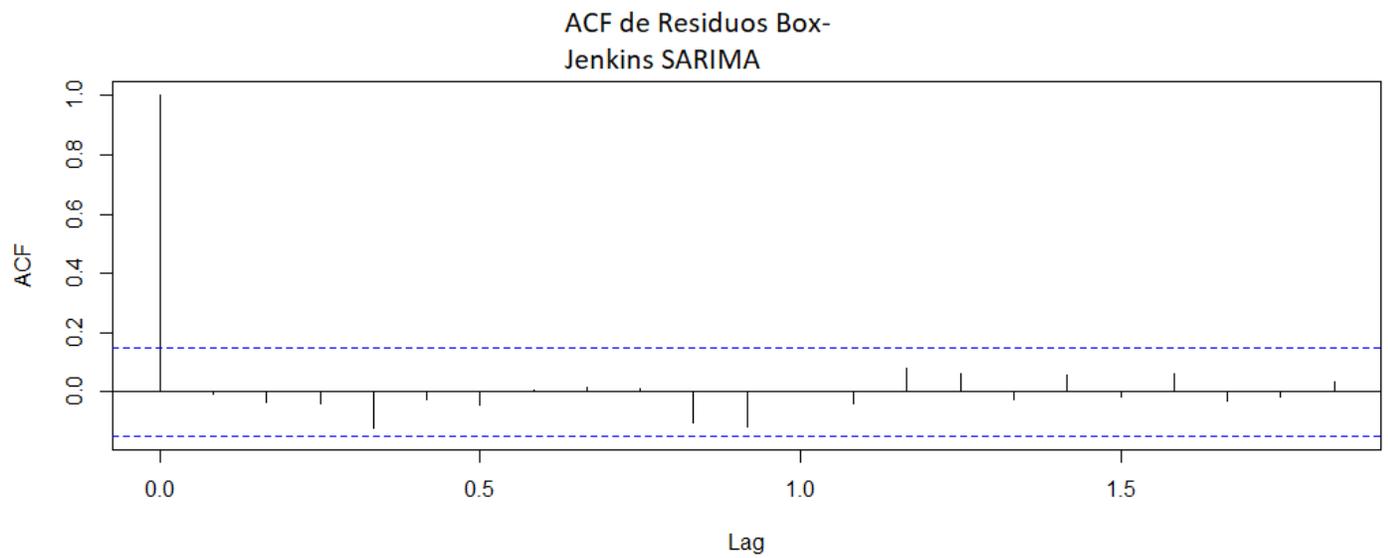


Figura 20. Cotizantes AFP: ACF de residuos de Box-Jenkins SARIMA. P-value de Box-Pierce test 0.908

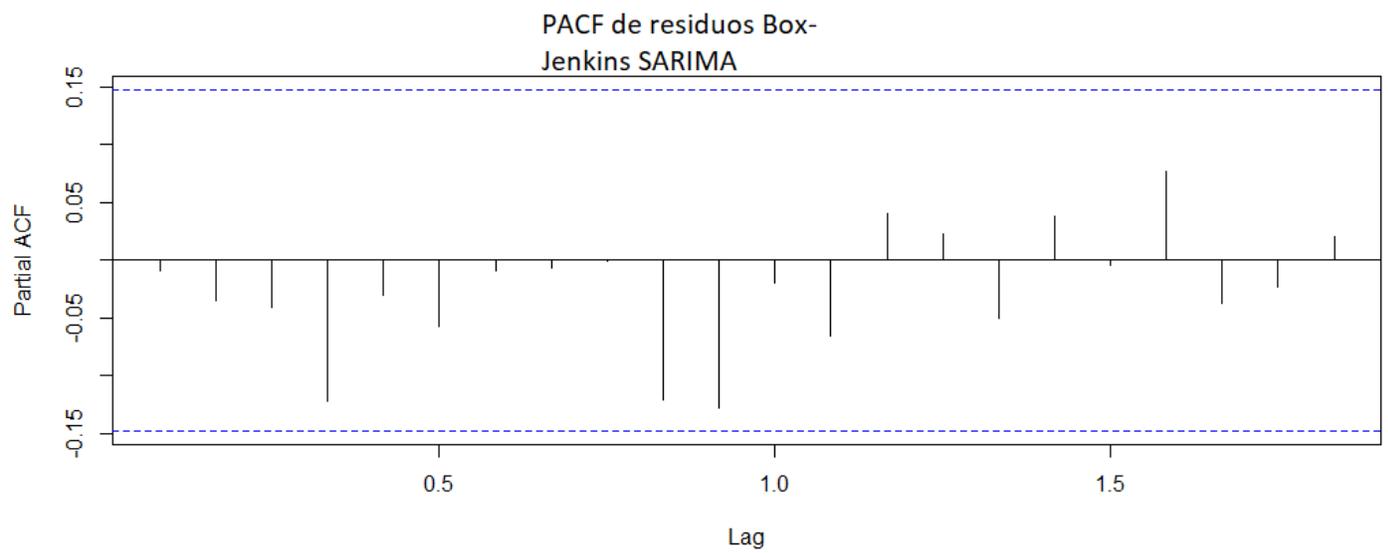


Figura 21. Cotizantes AFP: PACF de residuos de Box-Jenkins SARIMA.

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
mean	1,892	-3,458	19,673	-14,800	62,995	6,153
sd	134,197	139,101	134,611	135,483	91,329	156,512
0 %	-528,759	-552,158	-499,087	-544,997	-92,343	-532,773
25 %	-32,477	-40,074	-5,501	-38,868	10,285	-52,184
50 %	15,985	13,883	33,832	8,343	47,727	5,268
75 %	63,618	54,082	68,560	38,980	96,772	58,642
100 %	459,742	483,088	598,228	538,091	542,694	380,327

Tabla 24: Parámetros de la distribución de los errores de predicción

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	93.33	88.33	93.33	93.33	76.67	83.33
step 2	86.67	88.33	90	90	80	85
step 3	88.33	85	91.67	90	70	83.33
step 4	86.67	81.67	90	88.33	73.33	76.67
step 5	85	81.67	86.67	88.33	73.33	75
step 6	83.33	80	86.67	86.67	73.33	66.67

Tabla 25: Hit de las observaciones en las bandas de una desviación estándar

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	95	96.67	95	95	96.67	95
step 2	95	95	93.33	93.33	96.67	91.67
step 3	93.33	93.33	91.67	93.33	93.33	90
step 4	91.67	91.67	90	90	93.33	90
step 5	90	90	88.33	88.33	90	93.33
step 6	91.67	93.33	91.67	88.33	90	95

Tabla 26: Hit de las observaciones en las bandas de dos desviaciones estándar

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	96.67	96.67	96.67	96.67	96.67	96.67
step 2	96.67	95	96.67	95	96.67	98.33
step 3	96.67	96.67	96.67	95	96.67	96.67
step 4	96.67	96.67	96.67	96.67	96.67	100
step 5	96.67	96.67	96.67	96.67	96.67	100
step 6	98.33	98.33	98.33	95	96.67	100

Tabla 27: Hit de las observaciones en las bandas de tres desviaciones estándar

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	4,177	2,369	23,120	7,228	12,674	2,038
sd	40,908	80,598	77,274	79,442	68,484	93,625
percentil 0 %	-274,878	-536,522	-497,805	-537,539	-451,011	-516,237
25 %	-12,270	-26,000	-3,018	-21,509	-18,360	-37,826
50 %	6,064	6,526	27,820	12,280	11,449	125
75 %	24,942	40,973	59,762	47,136	47,206	44,154
100 %	205,412	505,775	326,732	503,437	307,881	469,304

Tabla 28: Parámetros de la distribución de los errores de predicción con la data sintética

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	88.33	76.67	75.03	75.85	83.87	75.317
step 2	84.24	75.53	73.83	74.85	78.67	74.53
step 3	78.50	74.32	69.27	72.47	75.2	73.77
step 4	74.61	73.08	68.58	71.52	68.83	72.85
step 5	68.29	72.92	65.25	70.12	67.8	72.43
step 6	64.75	72.83	60.05	68.22	64.27	72.13

Tabla 29: Hit de las observaciones en las bandas de una desviación estándar con la data sintética

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	97.85	94.28	95.17	94.73	97.03	94.65
step 2	97	94.1	93.2	93.4	95.87	94.07
step 3	95.32	93.83	93.12	93.65	95.63	93.67
step 4	94.09	93.55	90.6	92.7	92.17	93.4
step 5	90.57	92.58	88.62	91.33	91.17	93.35
step 6	89.39	92.3	86.98	90.77	89.23	93.98

Tabla 30: Hit de las observaciones en las bandas de dos desviaciones estándar con la data sintética

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	99.28	98.93	98.75	98.88	99.7	98.73
step 2	98.65	98.7	98.15	98.6	99.27	98.68
step 3	98.05	98.25	97.83	98.23	98.7	99.07
step 4	97.41	98.78	97.8	98.55	98.3	99.38
step 5	96.28	99.03	97.75	98.62	97.67	99.55
step 6	95.39	99.15	98.05	98.67	97.2	99.42

Tabla 31: Hit de las observaciones en las bandas de tres desviaciones estándar con la data sintética

.0.2 *Indice Mensual de Actividad Económica*

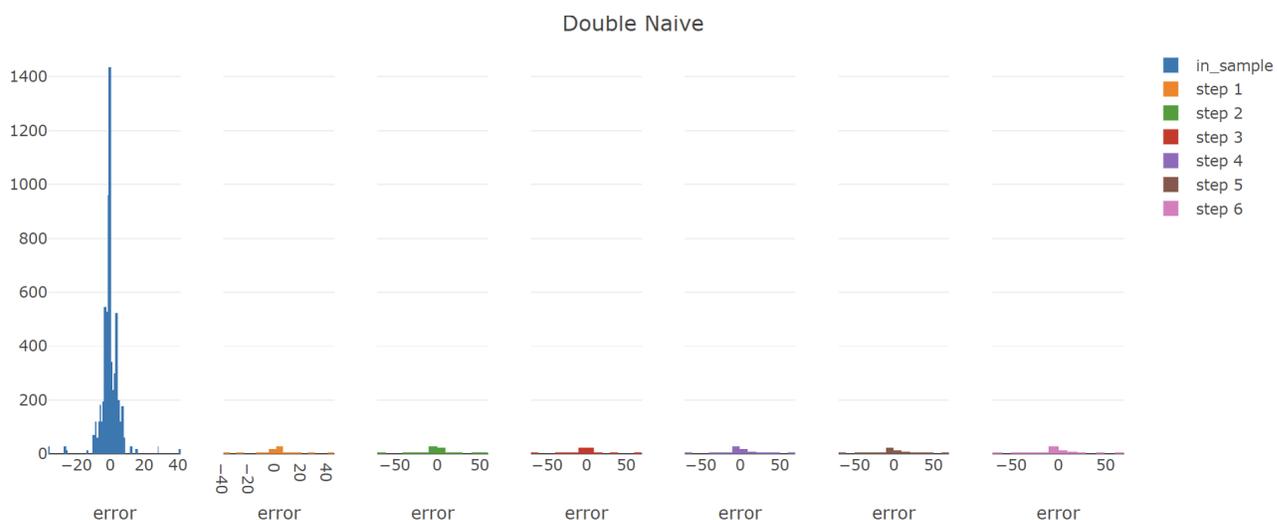


Figura 22. Residuos Double Naive IMAE

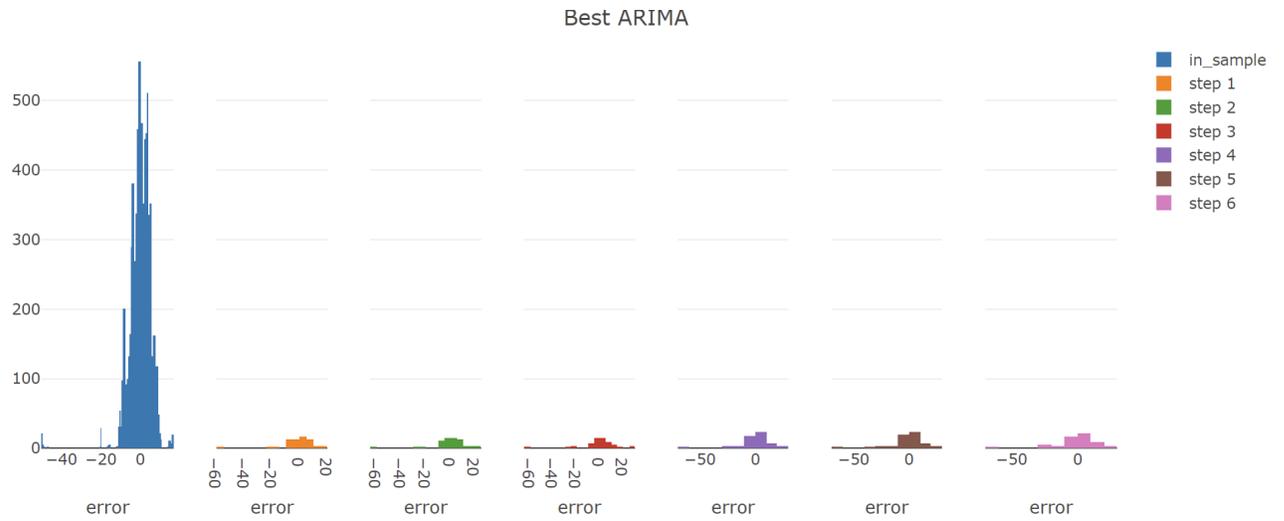


Figura 23. Residuos de Grid/Best ARIMA para IMAE

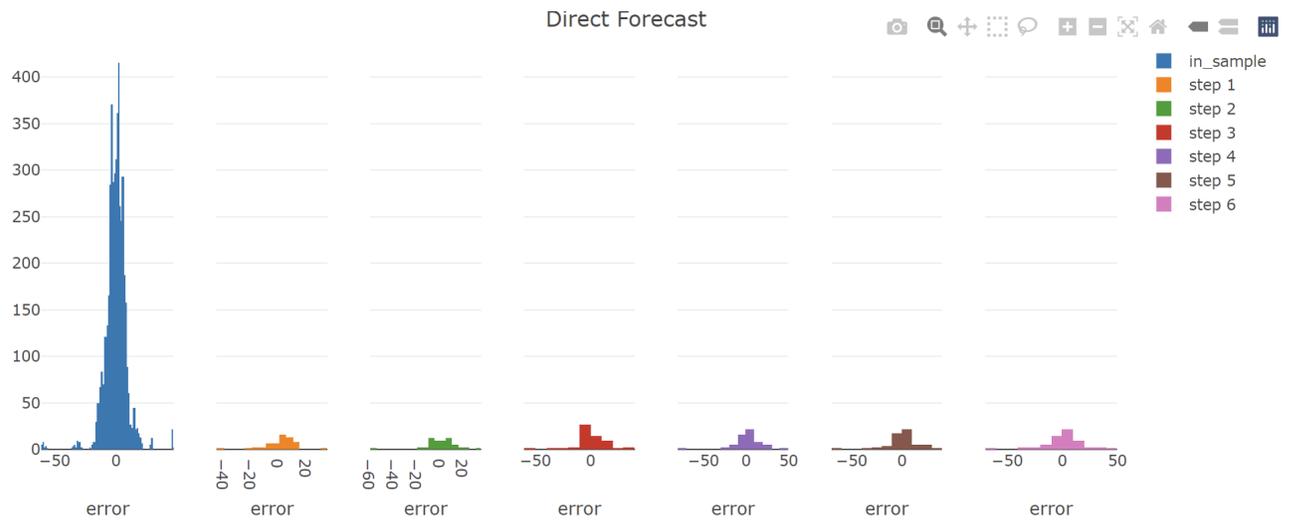


Figura 24. Residuos de Direct Forecast para IMAE

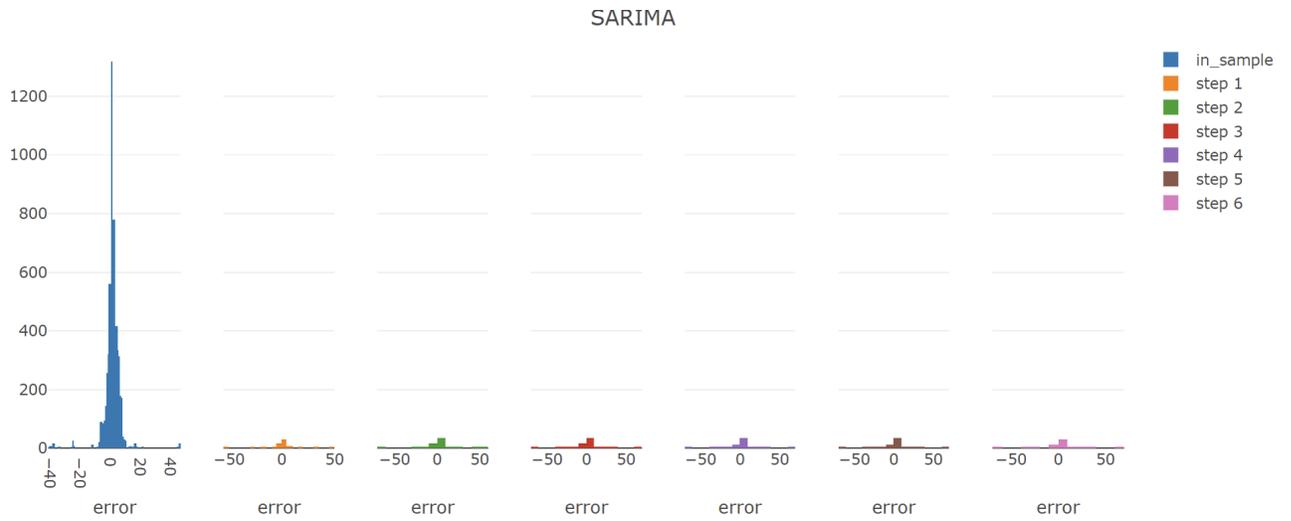


Figura 25. Residuos de SARIMA para IMAE

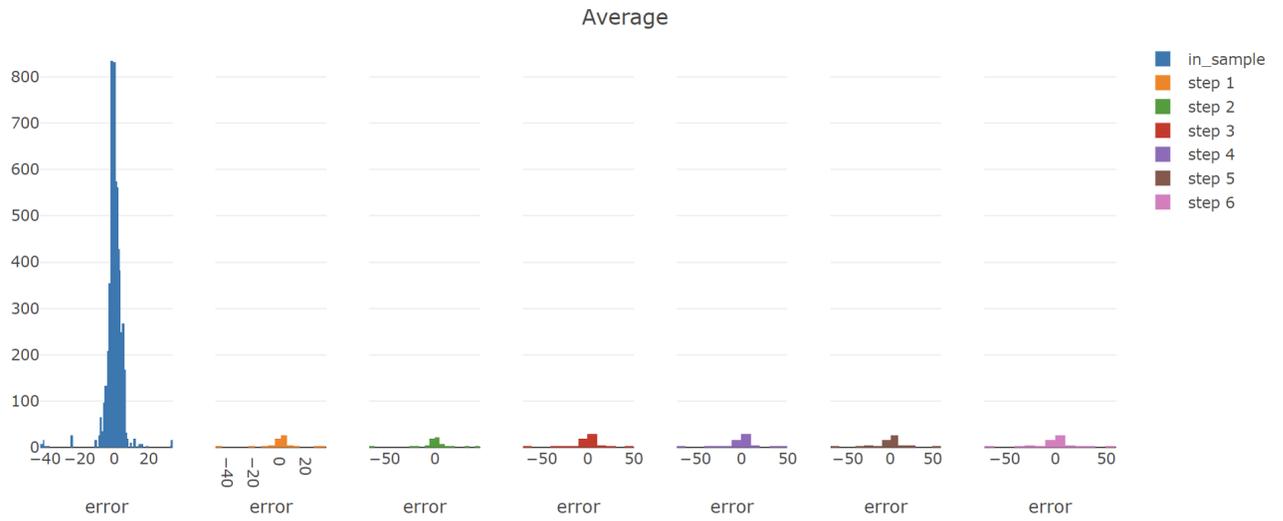


Figura 26. Residuos de Average Forecast Combination para IMAE

ACF residuos SARIMA

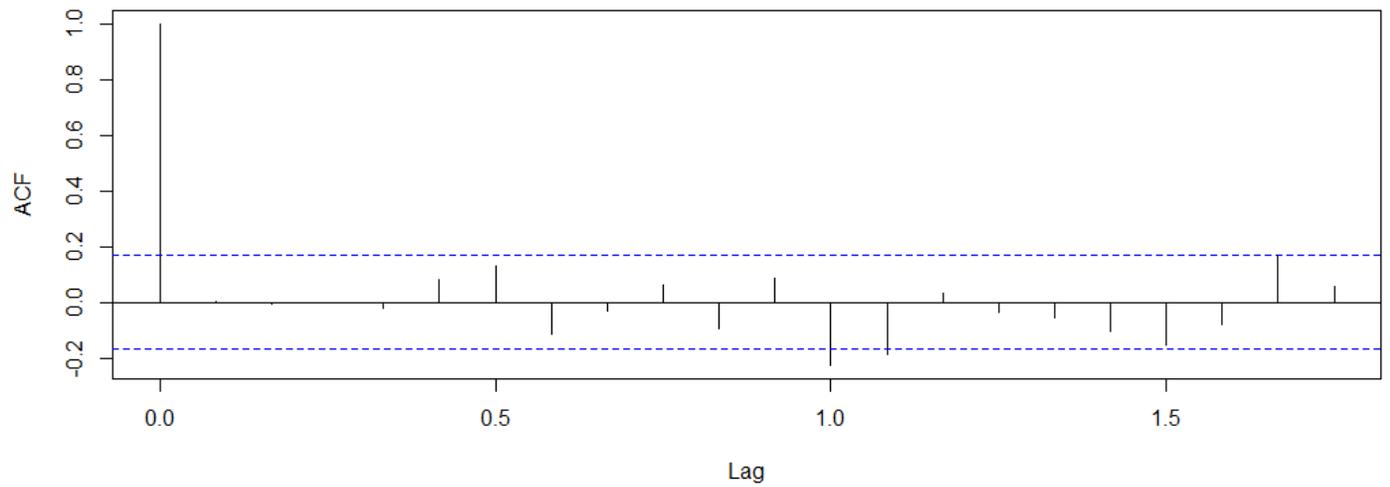


Figura 27. IMAE: ACF de residuos de SARIMA. P-value de Box-Pierce test 0.9644

PACF residuos SARIMA

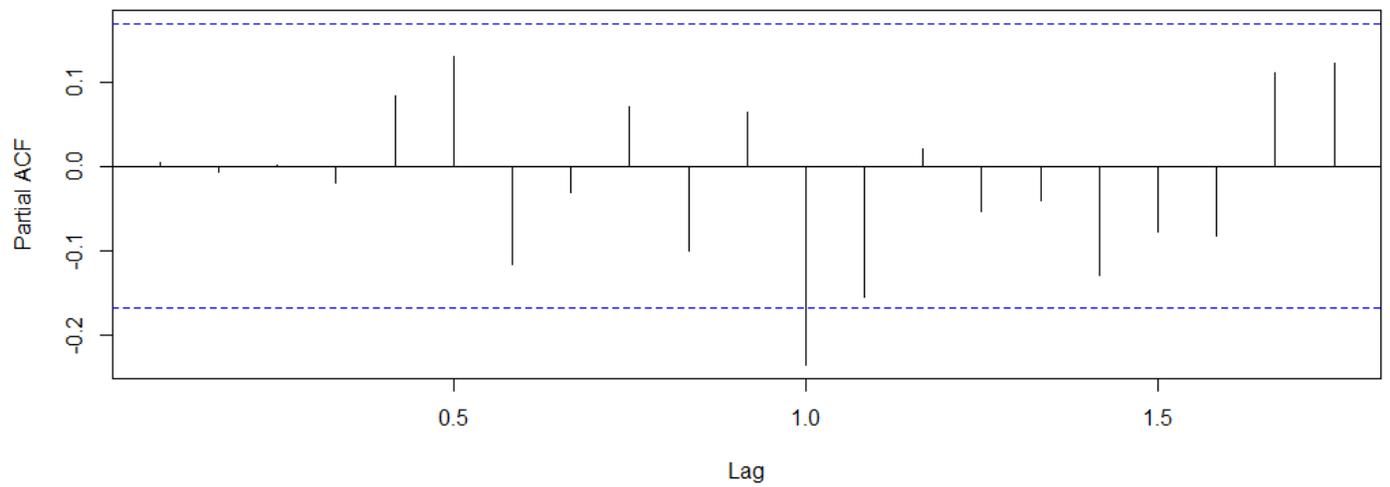


Figura 28. IMAE: PACF de residuos de SARIMA.

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
media	0.14	0.55	-0.012	0.05	0.31
sd	5.70	5.25	5.73	8.33	4.93
percentil 0 %	-63.69	-63.32	-65.4	-71.51	-63.93
25 %	-2.55	-1.15	-1.8	-3.83	-1.18
50 %	0.47	0.44	0	0.34	0.24
75 %	3.53	2.53	2.3	4.41	2.19
100 %	27.73	63.94	67.1	46.76	51.97

Tabla 32: Parámetros de la distribución de los errores de predicción para Índice Mensual de Actividad Económica (IMAE)

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	86.67	90	86.67	78.33	90
step 2	88.33	86.67	88.33	81.67	86.67
step 3	86.67	86.67	86.67	81.67	86.67
step 4	78.33	85	83.33	78.33	85
step 5	80	81.67	81.67	78.33	81.67
step 6	75	78.33	78.33	76.67	80

Tabla 33: Hit de las bandas para una desviación estándar para Índice Mensual de Actividad Económica (IMAE)

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	98.33	93.33	91.67	95	93.33
step 2	96.67	95	93.33	96.67	95
step 3	93.33	91.67	91.67	91.67	93.33
step 4	95	91.67	91.67	96.67	91.67
step 5	96.67	91.67	91.67	95	95
step 6	95	93.33	91.67	95	91.67

Tabla 34: Hit de las bandas para dos desviaciones estándar para Índice Mensual de Actividad Económica (IMAE)

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	98.33	96.67	96.67	96.67	96.67
step 2	98.33	95	96.67	98.33	96.67
step 3	98.33	96.67	96.67	98.33	96.67
step 4	98.33	96.67	96.67	98.33	96.67
step 5	98.33	96.67	96.67	98.33	96.67
step 6	98.33	96.67	96.67	98.33	96.67

Tabla 35: Hit de las bandas para tres desviaciones estándar para Índice Mensual de Actividad Económica (IMAE)

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
media	-0.09	0.98	-0.01	0.10	0.31
sd	6.64	7.82	8.75	9.42	4.94
percentil 0 %	-70.29	-84.59	-108.8	-75.19	-63.93
25 %	-3.29	-2.17	-3.4	-4.19	-1.18
50 %	0.33	0.72	0.01	0.43	0.24
75 %	3.62	4.49	3.5	4.99	2.19
100 %	58.11	74.27	80.5	54.28	51.97

Tabla 36: Parámetros de la distribución de los errores de predicción para Índice Mensual de Actividad Económica (IMAE) con la data sintética

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	72.75	26.93	74.85	67.11	85.07
step 2	75.58	33.34	75.49	69.84	82.95
step 3	74.34	34.43	74.16	70.95	80.61
step 4	74.69	35.37	74.58	67.33	76.98
step 5	74.96	36.39	74.45	67.62	78.02
step 6	72.64	36.94	73.47	66.74	76.03

Tabla 37: Hit de las bandas para una desviación estándar para Índice Mensual de Actividad Económica (IMAE) con la data sintética

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	95.74	50.08	93.92	95.13	97.38
step 2	94.84	60.49	94.31	92.37	96.44
step 3	94.84	62.04	94.39	91.92	95.27
step 4	94.38	63.51	94.70	91.79	94.29
step 5	94.34	64.98	94.47	91.14	93.82
step 6	93.72	65.83	94.51	90.50	92.93

Tabla 38: Hit de las bandas para dos desviaciones estándar para Índice Mensual de Actividad Económica (IMAE) con la data sintética

	Best ARIMA	SARIMA	Double Naive	Direct Forecast Regression	Average
step 1	99.07	68.15	98.67	98.74	99.18
step 2	98.68	78.69	98.83	98.58	98.78
step 3	98.49	80.28	98.77	97.78	97.89
step 4	98.60	81.57	98.89	98.19	97.92
step 5	98.60	82.85	98.67	97.61	97.64
step 6	98.88	83.56	98.86	97.73	97.12

Tabla 39: Hit de las bandas para tres desviaciones estándar para Índice Mensual de Actividad Económica (IMAE) con la data sintética

.0.3 Remesas

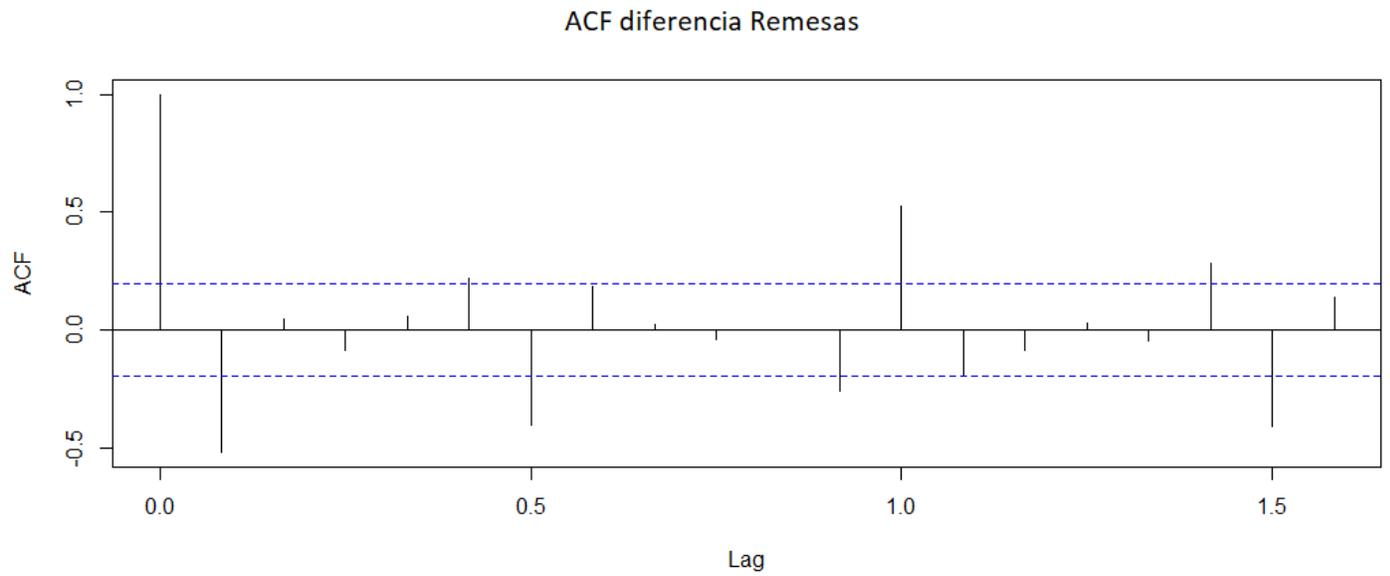


Figura 29. Remesas: ACF de la diferencia intermensual de las remesas.

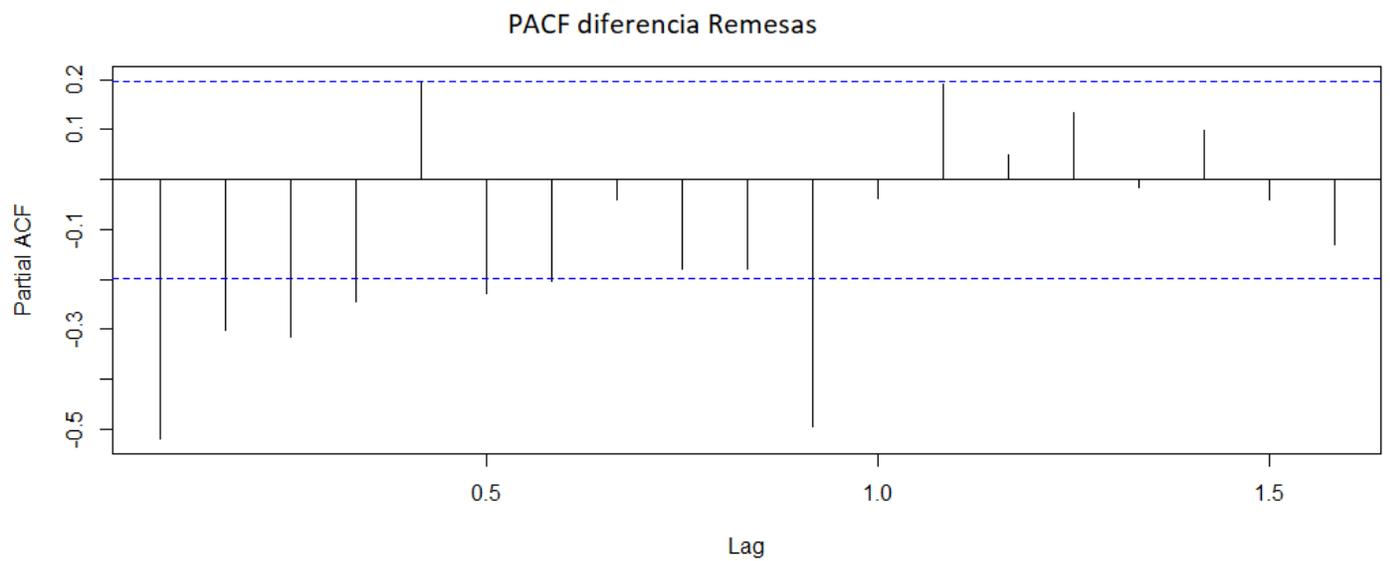


Figura 30. Remesas: PACF de la diferencia intermensual de las remesas.

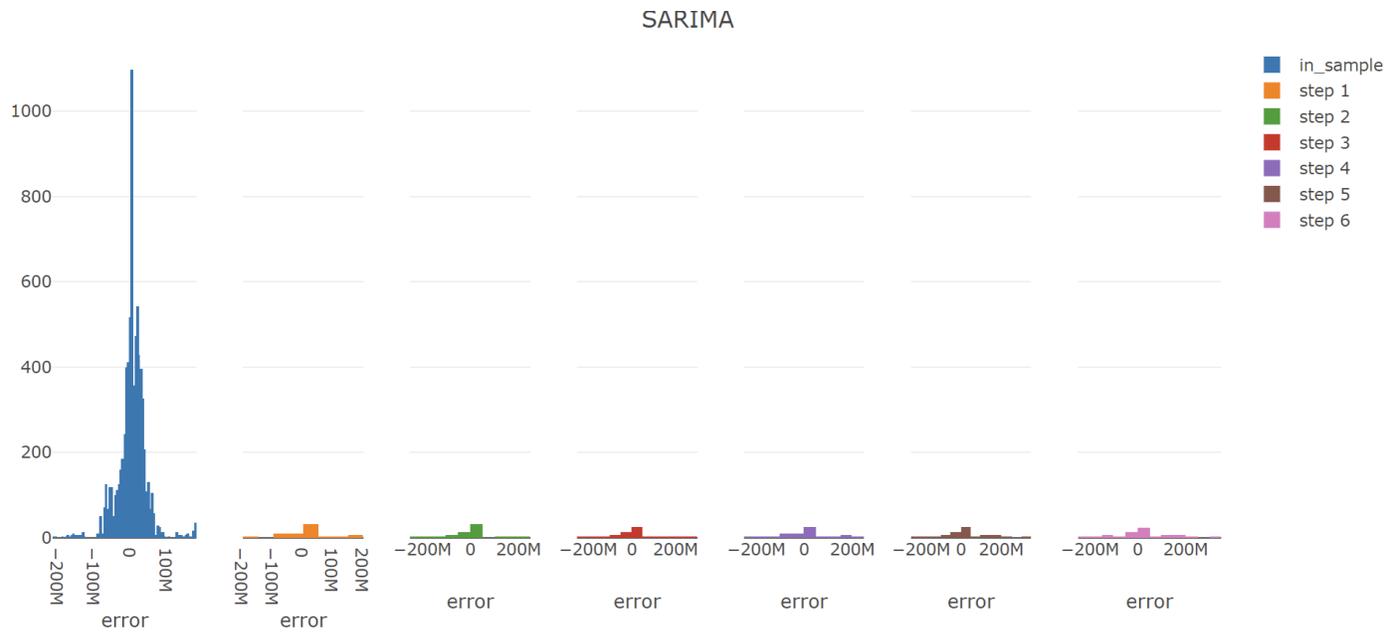


Figura 31. Residuos de SARIMA para Remesas

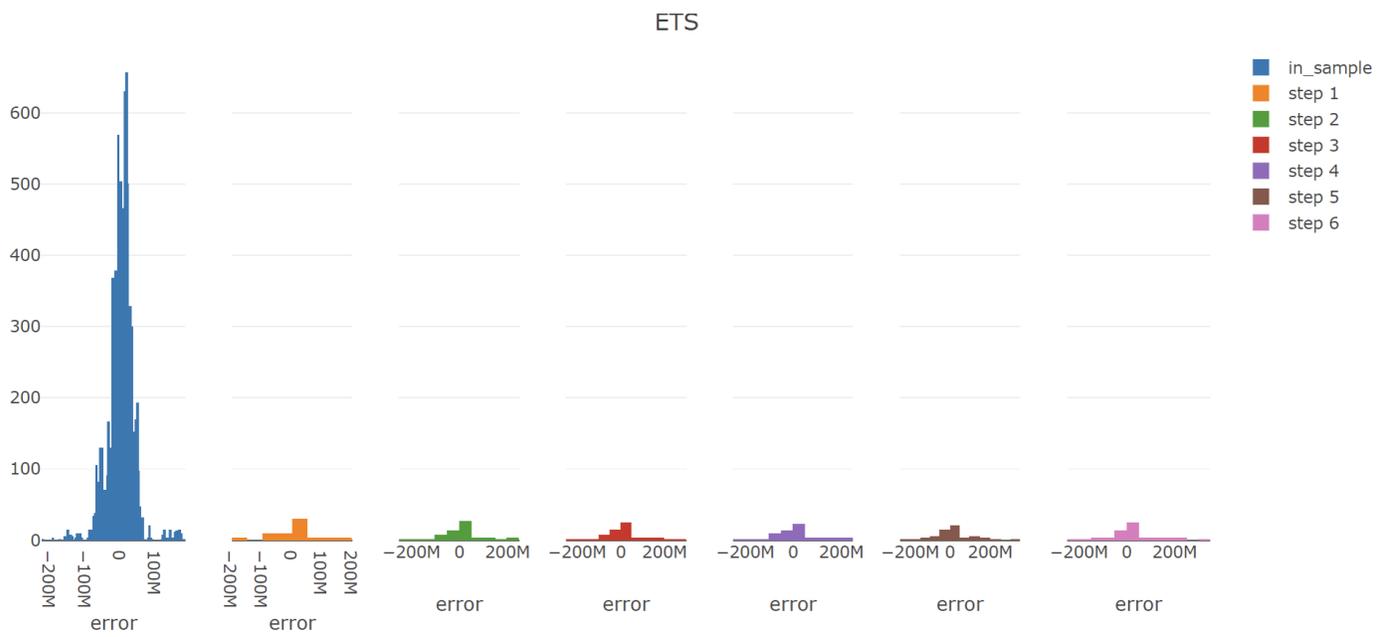


Figura 32. Residuos de ETS para Remesas

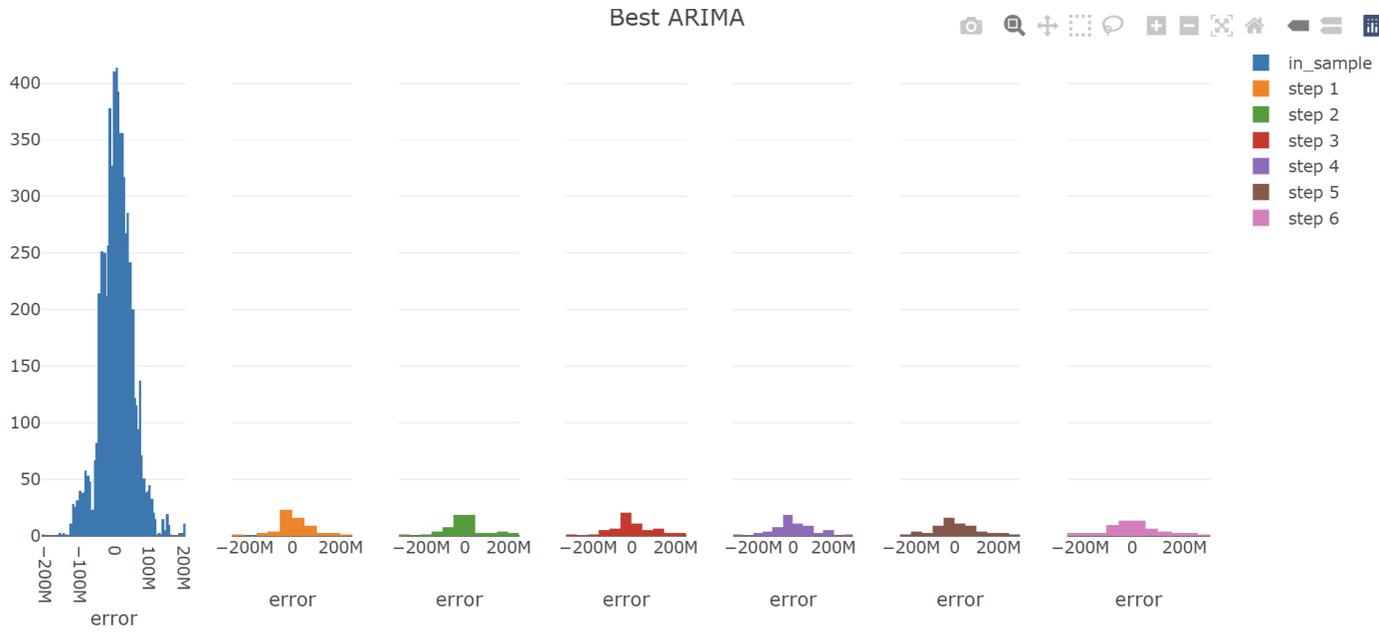


Figura 33. Residuos de Grid/Best ARIMA para Remesas

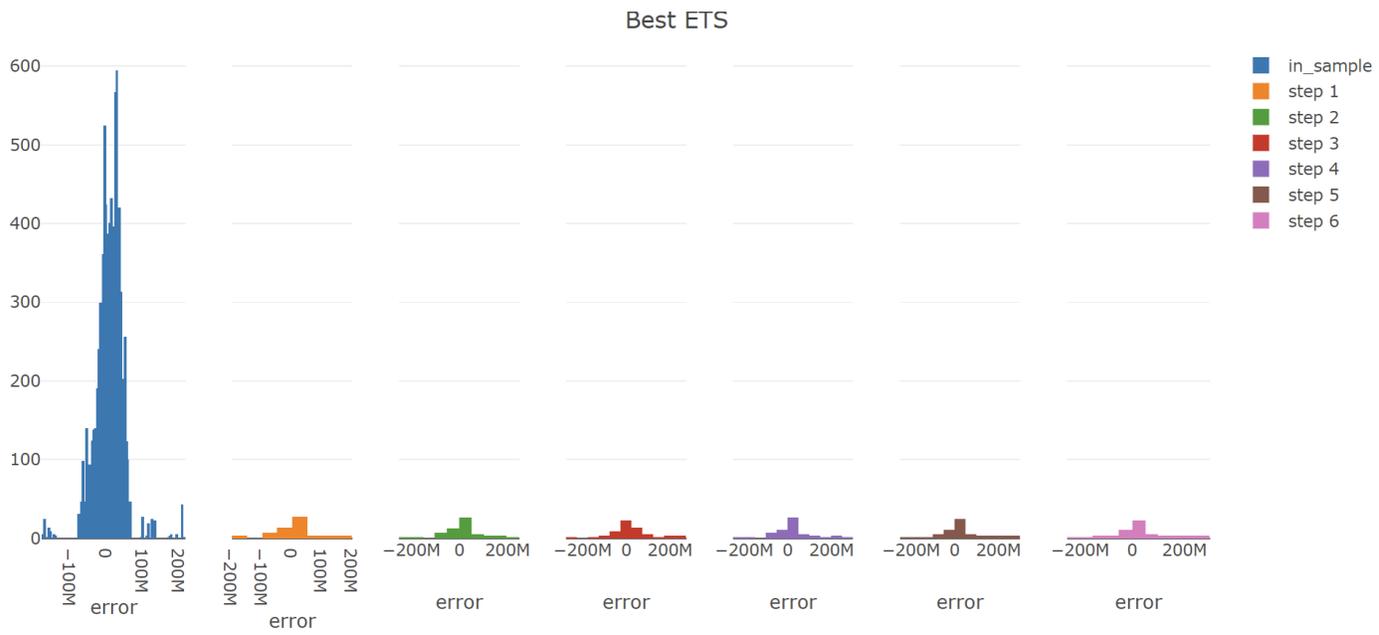


Figura 34. Residuos de Grid/Best ETS para Remesas

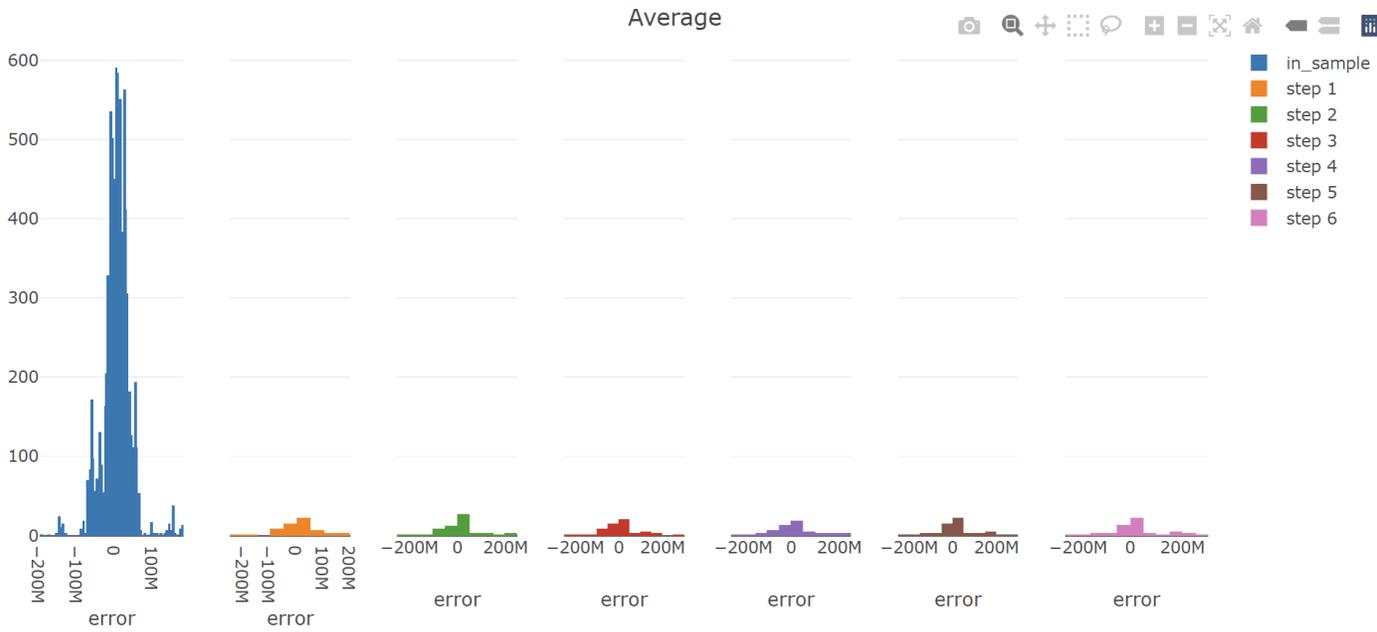


Figura 35. Residuos de Average Combination para Remesas

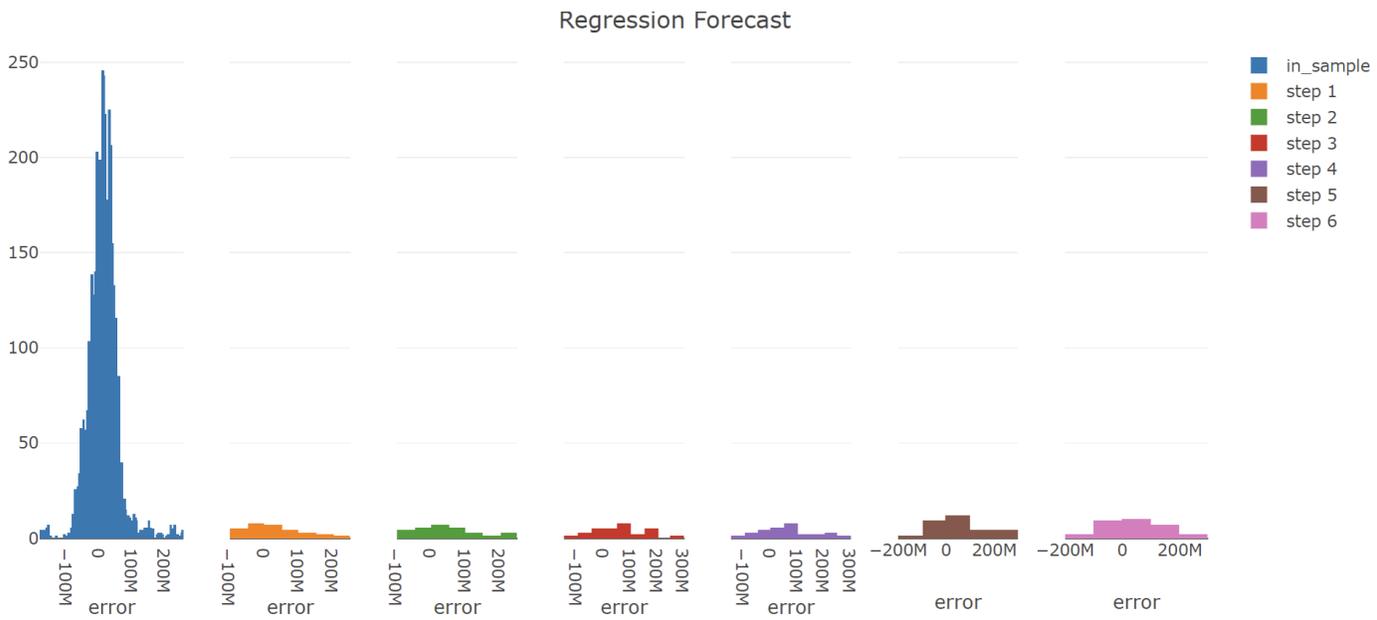


Figura 36. Residuos de Regression Forecast Combination para Remesas

ACF Residuos SARIMA

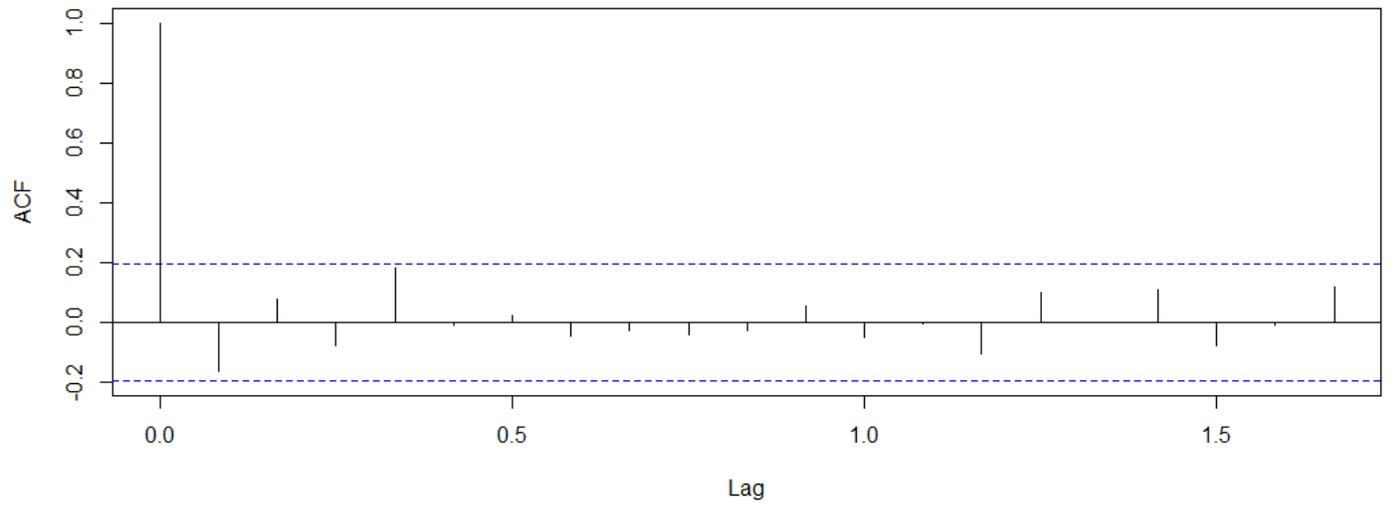


Figura 37. ACF de los residuos del SARIMA

Residuos PACF SARIMA

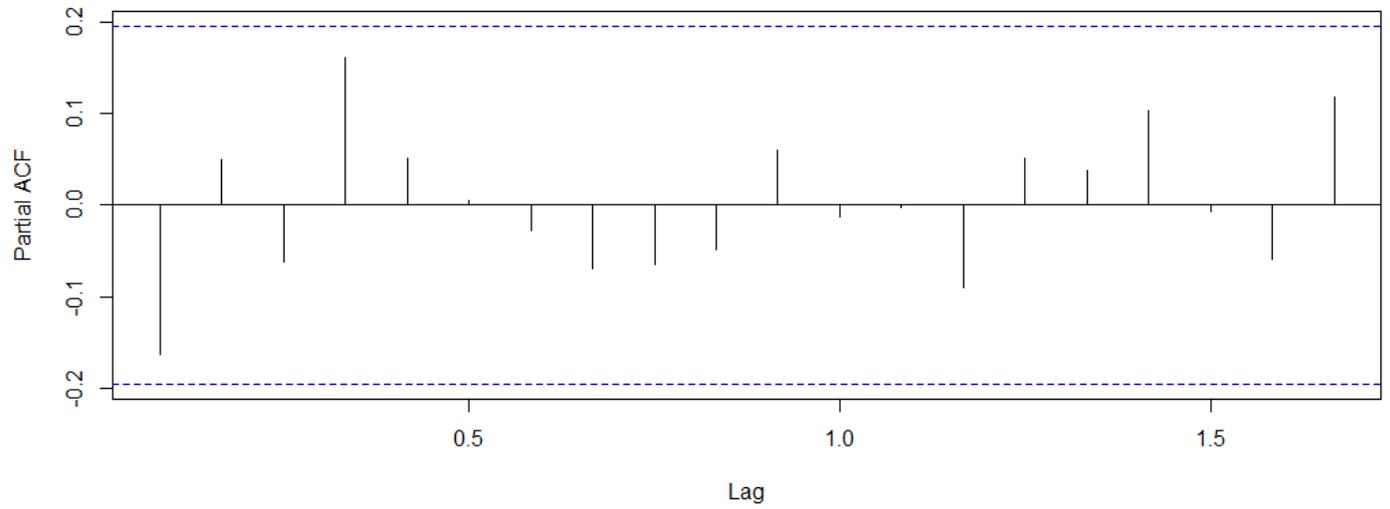


Figura 38. PACF de los residuos del SARIMA

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast	SARIMA
mean	14,953,116	4,024,223	24,765,830	17,629,122	46,774,333	13,393,288
sd	85,069,017	96,755,964	87,595,586	83,472,667	93,921,753	86,148,246
0 %	-236,804,757	-255,122,878	-231,089,541	-236,252,931	-128,536,937	-229,582,483
25 %	-23,772,343	-48,515,843	-20,104,423	-22,810,854	-23,832,399	-29,377,390
50 %	9,750,355	-9,778,154	18,601,126	11,049,618	38,183,650	11,903,574
75 %	40,897,211	53,972,126	49,638,868	40,040,954	103,673,861	35,981,183
100 %	299,969,191	295,933,696	289,099,576	358,316,976	252,307,749	318,530,655

Tabla 40: Parámetros de la distribución de los errores de predicción para remesas

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	78.33	76.67	76.67	76.67	80	76.67
step 2	78.33	76.67	73.33	78.33	80	76.67
step 3	75	76.67	70	75	76.67	73.33
step 4	73.33	73.33	73.33	76.67	71.67	63.33
step 5	73.33	71.67	71.67	75	70	60
step 6	66.67	73.33	73.33	75	71.67	53.33

Tabla 41: Hit de las bandas a una desviación estándar

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	90	90	93.33	90	90	96.67
step 2	90	90	93.33	88.33	93.33	93.33
step 3	95	93.33	93.33	86.67	95	93.33
step 4	91.67	93.33	96.67	86.67	90	86.67
step 5	95	95	95	90	90	93.33
step 6	93.33	91.67	93.33	85	91.67	86.67

Tabla 42: Hit de las bandas a dos desviaciones estándar

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	100	100	98.33	100	100	100
step 2	100	100	100	100	100	100
step 3	98.33	100	100	100	98.33	100
step 4	100	100	100	100	100	100
step 5	98.33	100	100	98.33	98.33	100
step 6	98.33	100	100	100	100	100

Tabla 43: Hit de las bandas a tres desviaciones estándar

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
media	-11,145,203	1,261,503	-10,325,183	5,678,829	-1,916,411	-19,802,217
sd	121,100,792	118,361,970	120,247,918	120,607,986	62,024,474	148,124,572
percentil 0 %	-1,503,207,566	-1,464,304,473	-1,456,429,366	-1,436,759,051	-759,889,470	-1,460,344,433
25 %	-52,706,139	-37,308,587	-50,515,089	-37,255,202	-25,560,025	-49,880,943
50 %	-4,510,205	6,863,038	-4,248,250	11,399,092	614,721	-3,246,275
75 %	44,966,046	52,588,993	43,677,499	61,101,576	28,022,909	43,001,080
100 %	410,079,929	530,481,393	775,084,715	489,866,733	241,040,472	407,138,188

Tabla 44: Parámetros de la distribución de los errores de predicción con la data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	71.68	73.94	72.2	71.26	86.21	80.71
step 2	71.61	73.37	72.05	71.71	83.72	78.25
step 3	70.78	71.63	71.07	70.60	80.78	77.16
step 4	83.61	84.38	83.76	82.75	74.83	72.76
step 5	85.14	85.83	85.42	84.912	72.80	67.95
step 6	85.28	85.83	85.16	85.01	68.50	63.88

Tabla 45: Hit de las bandas a una desviación estándar con la data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	94.18	93.43	94.15	94.13	98.02	89.59
step 2	94.53	94.30	94.59	94.23	97.33	89.57
step 3	94.96	94.48	95.02	94.36	96.51	88.58
step 4	96.88	96.78	96.85	96.96	93.21	85.26
step 5	96.07	96.08	96.07	96.12	91.02	81.96
step 6	94.69	94.73	94.71	94.74	88.80	78.08

Tabla 46: Hit de las bandas a dos desviaciones estándar con la data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	99.54	99.50	99.47	99.23	99.81	91.35
step 2	99.23	98.81	99.05	99.14	99.25	90.66
step 3	99.13	98.98	99.13	99.18	99.15	90.72
step 4	98.44	98.42	98.4	98.44	97.22	87.97
step 5	97.05	96.99	97.02	97.06	95.93	85.82
step 6	95.88	95.86	95.83	95.97	94.30	83.54

Tabla 47: Hit de las bandas a tres desviaciones estándar con la data sintética

.04 Crédito Privado en Moneda Nacional

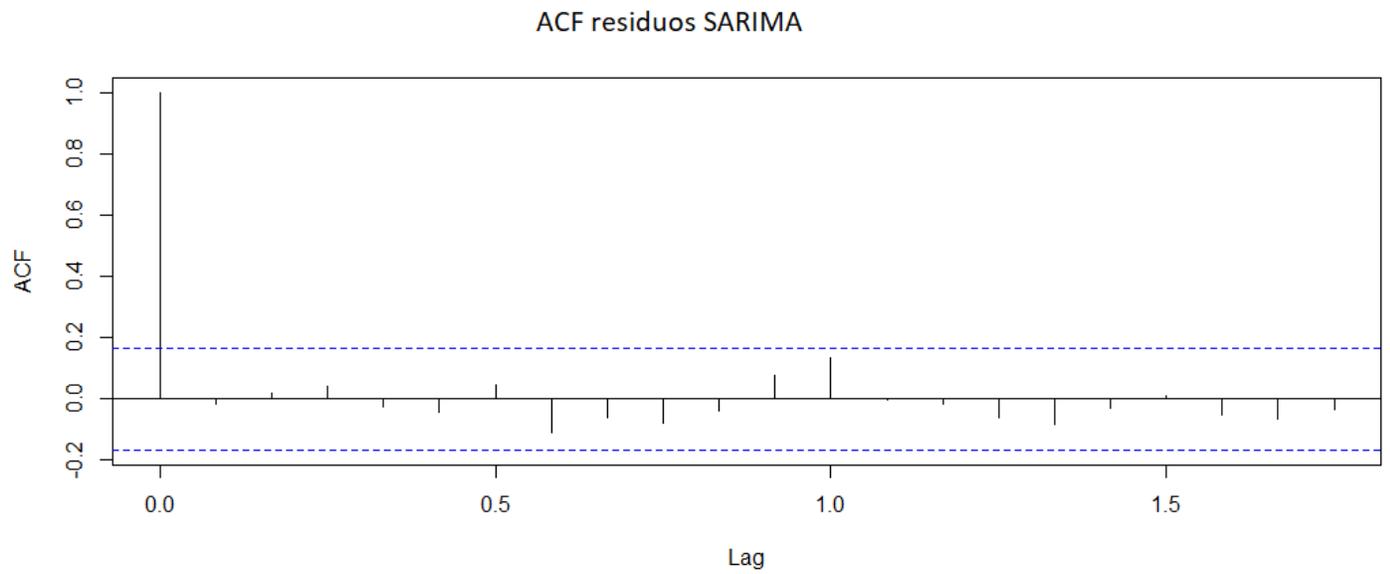


Figura 39. Crédito: ACF de los residuos del SARIMA. P-value del Box-Pierce test= 0.86

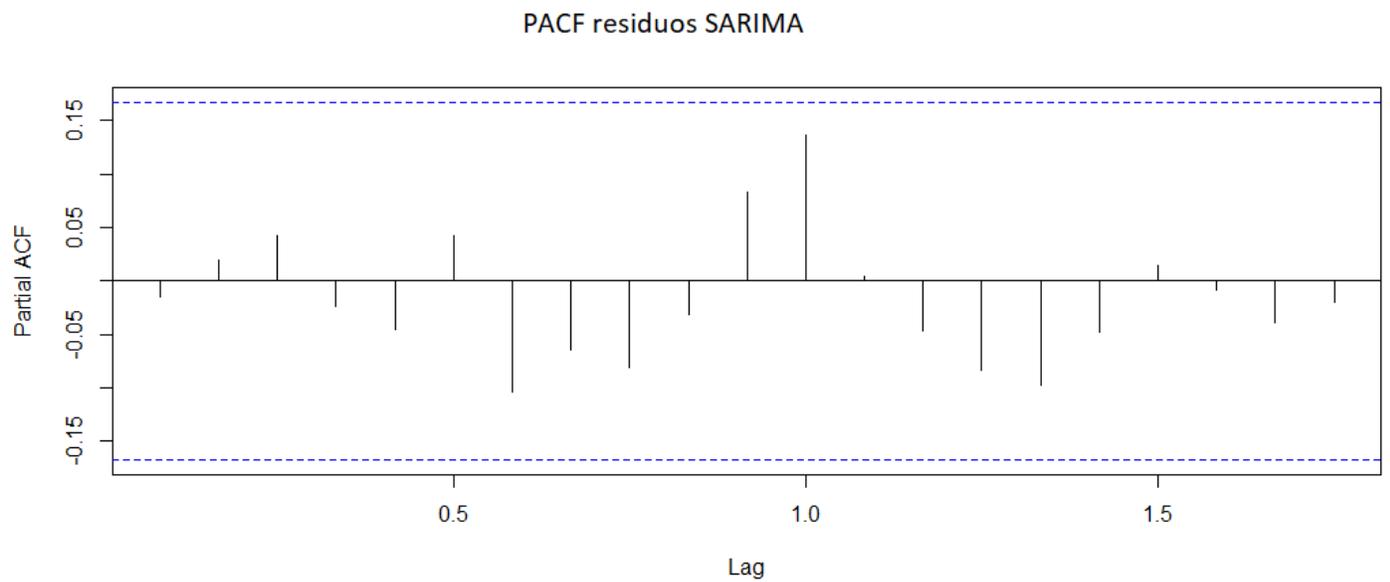


Figura 40. Crédito: PACF de los residuos del SARIMA.

ACF Diferencia Intermensual Crédito

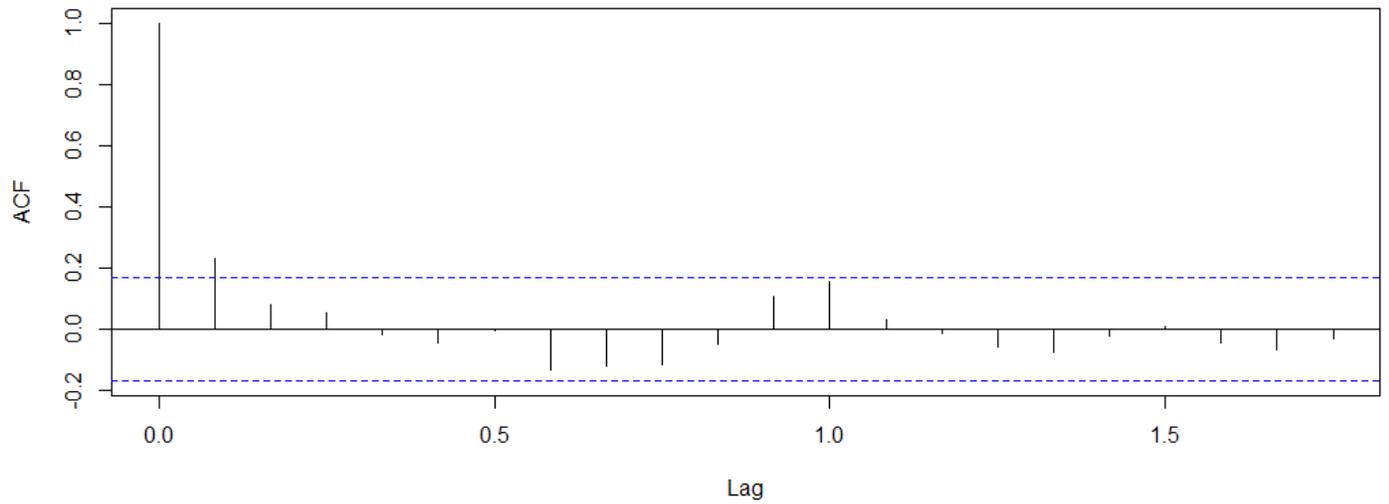


Figura 41. Crédito: ACF de la diferencia intermensual del crédito.

SARIMA

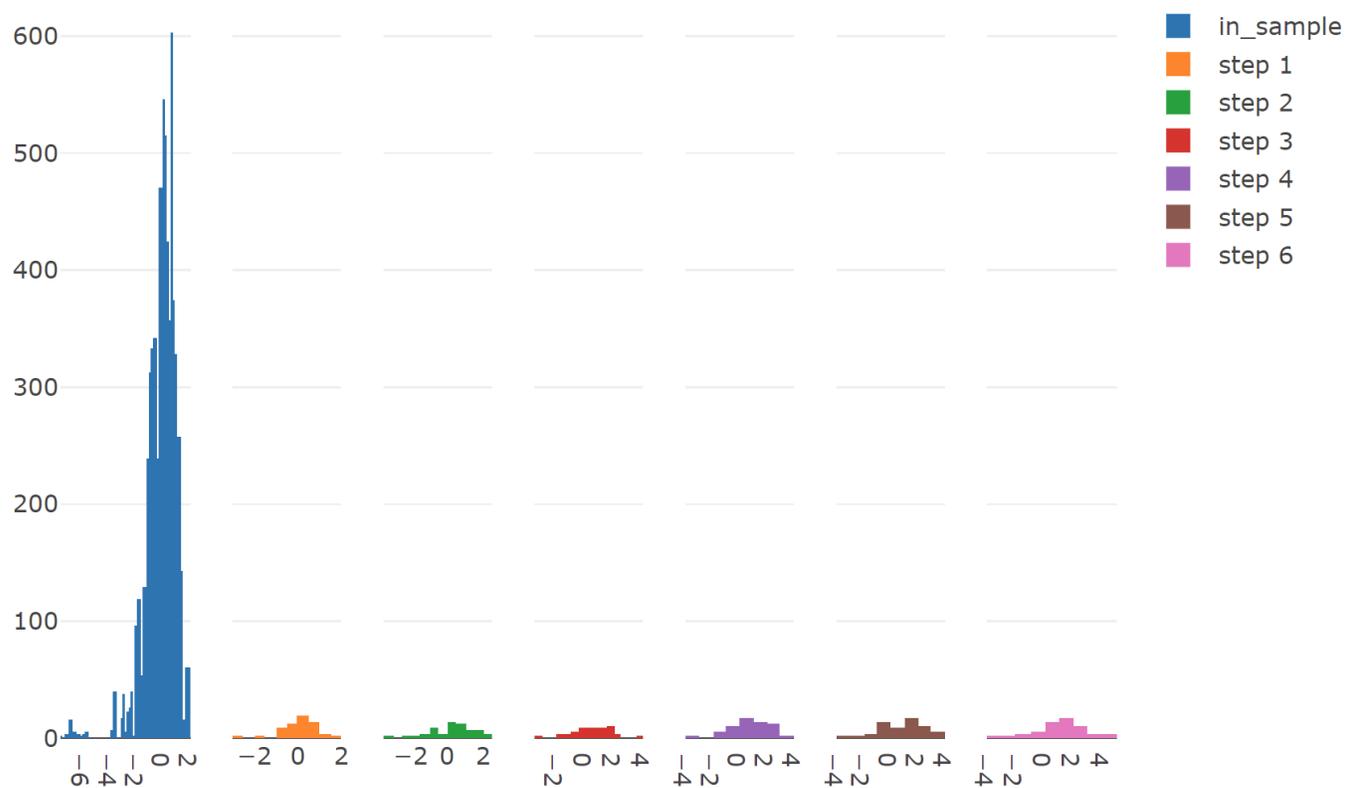


Figura 42. Crédito: errores del Box-Jenkins SARIMA .

ETS

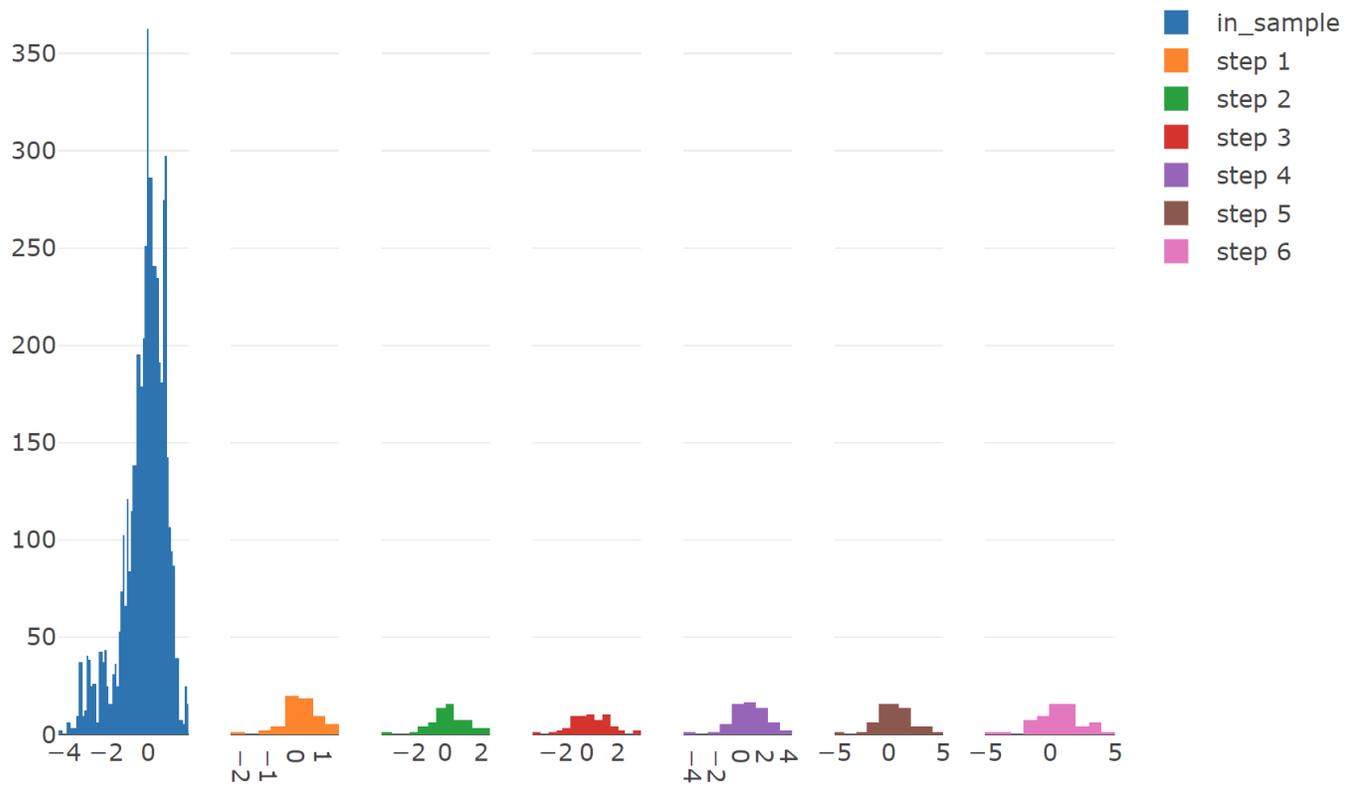


Figura 43. Crédito: errores del Minimum AIC ETS.

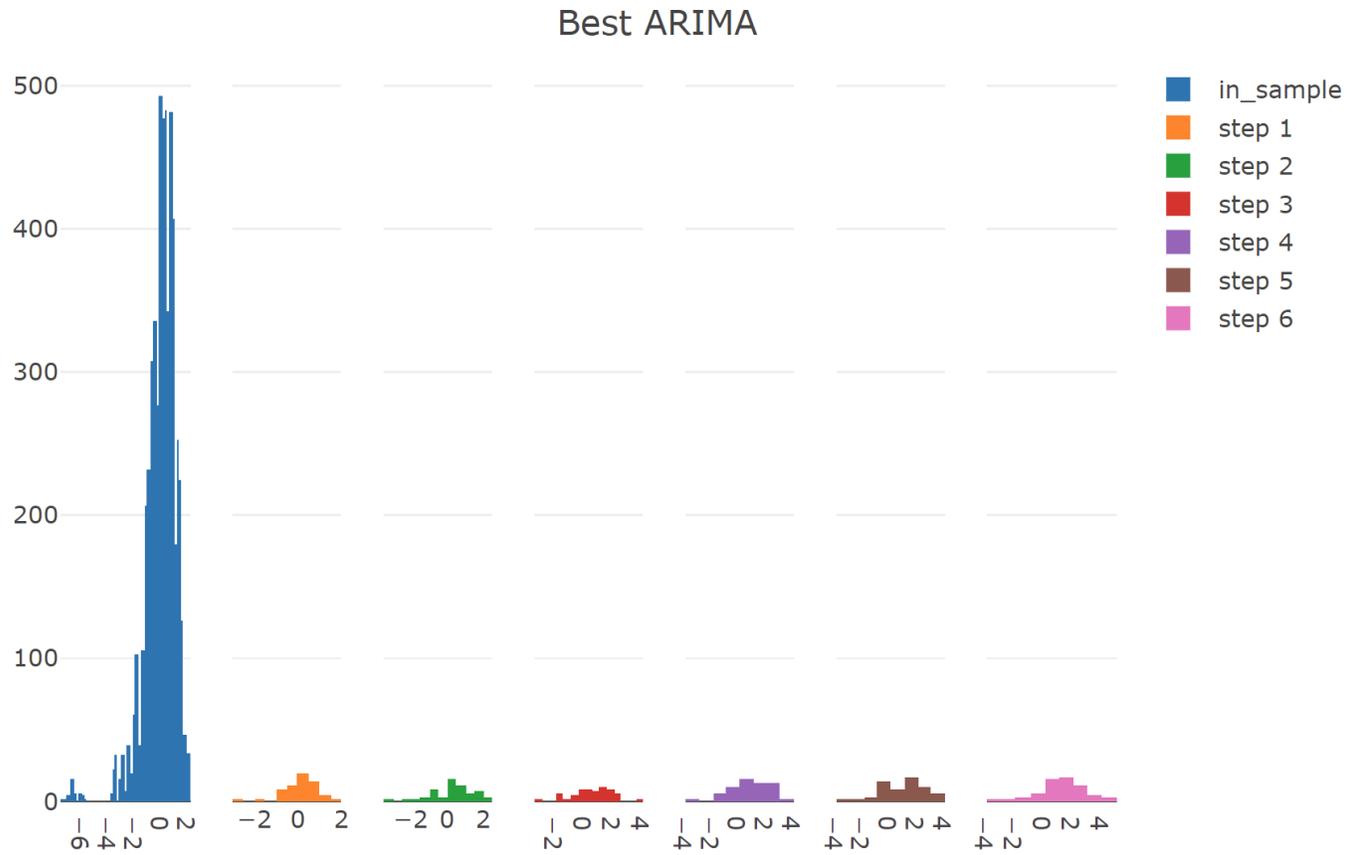


Figura 44. Crédito: errores del Grid/Best ARIMA.

Best ETS

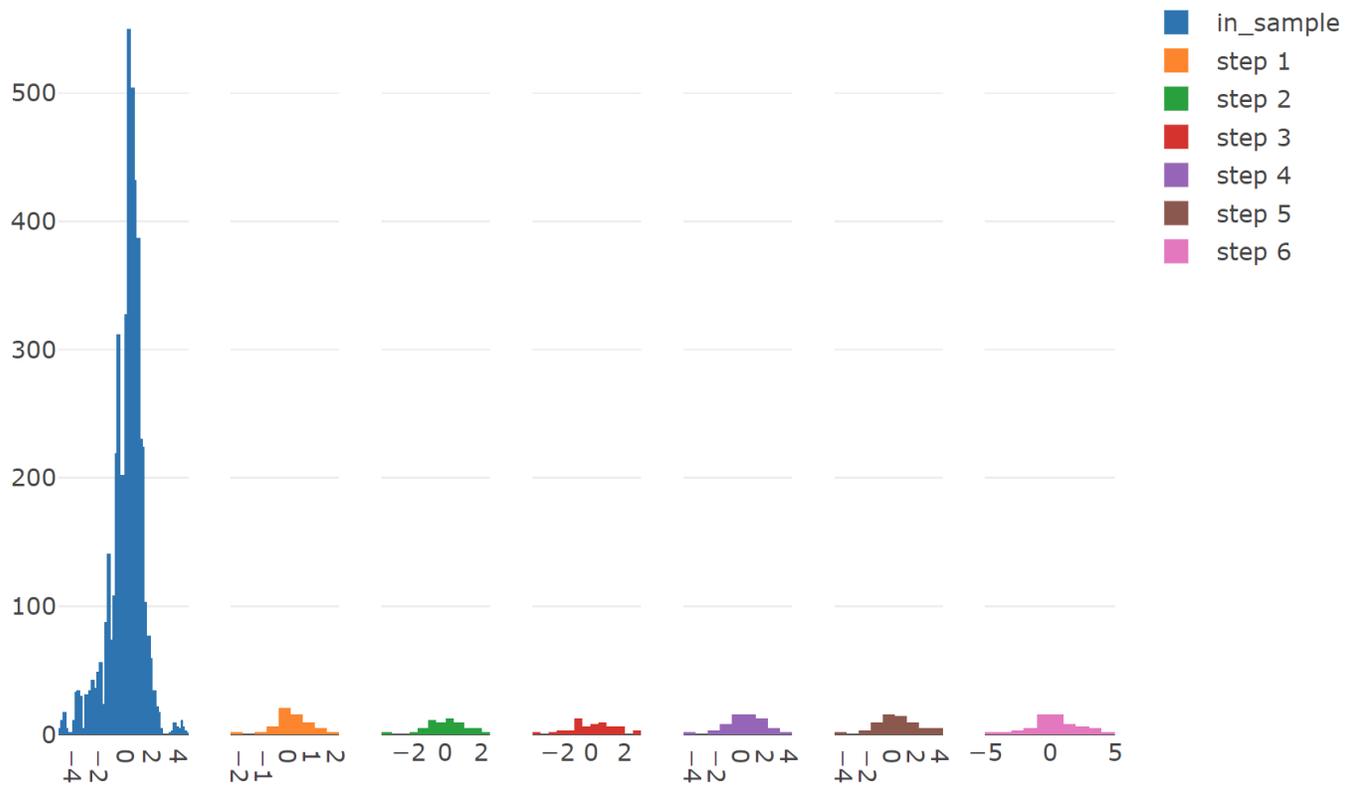


Figura 45. Crédito: errores del Grid/Best ETS.

Average

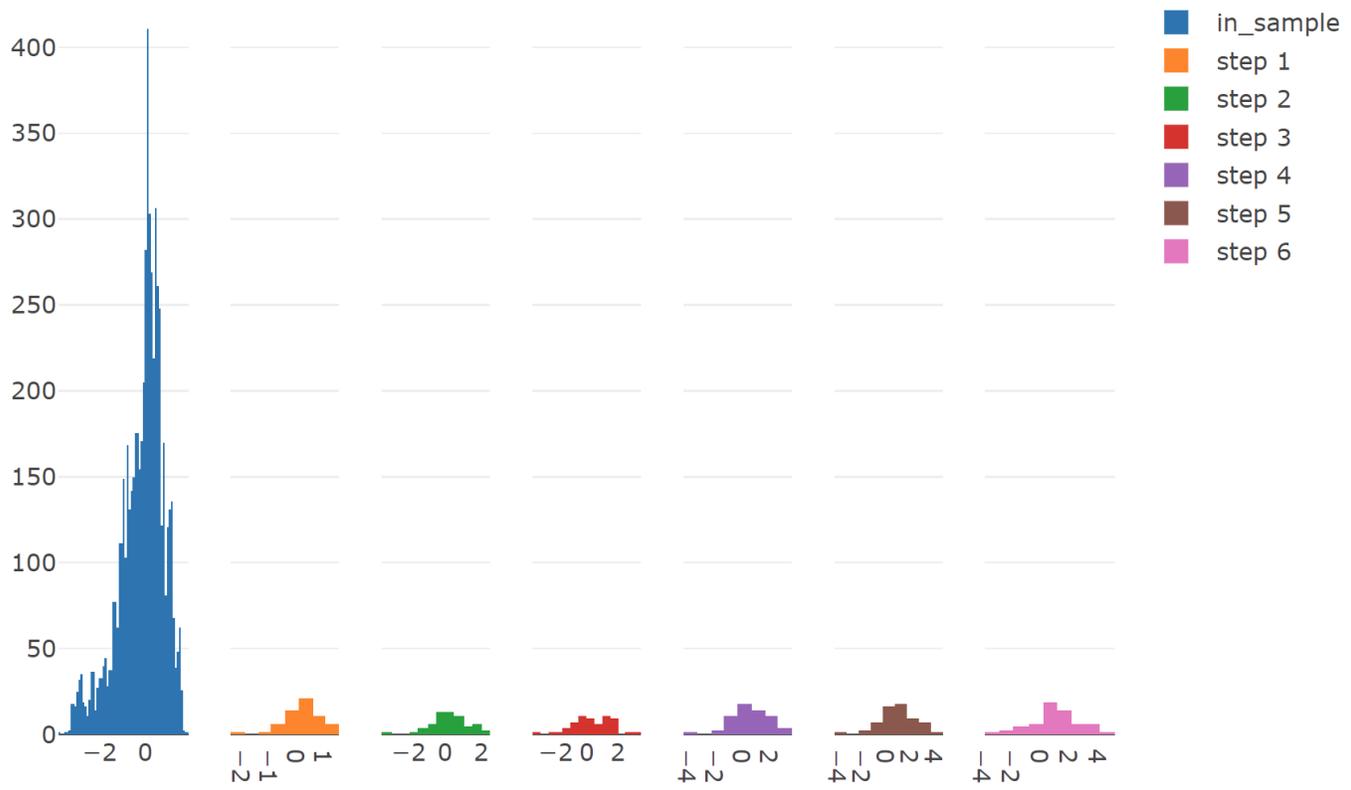


Figura 46. Crédito: errores del Average Forecast Combination.

Regression Forecast Combination

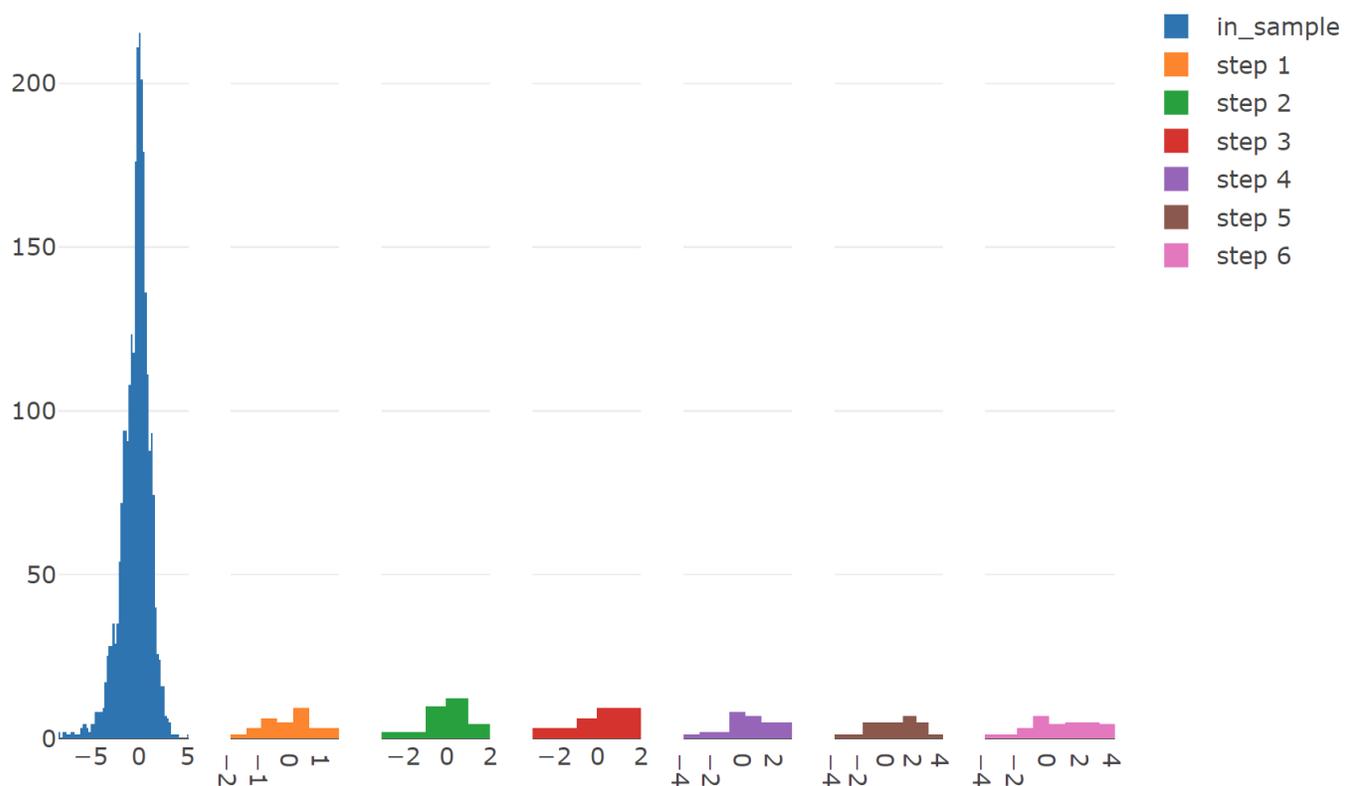


Figura 47. Crédito: errores del Regression Forecast Combination.

Modelos	Filtro 1: Bias	Filtro 2: Overfitting	Filtro 3: Tests de Optimalidad	Filtro 4: Hit Band
SARIMA	Si	Si	Si	Si
Minimum AIC ETS	Si	Si	Si	Si
Best ARIMA	Si	Si	Si	Si
Best ETS	Si	Si	Si	Si
Average Forecast Combination	Si	Si	Si	Si
Regression Combination	Si	Si	2	Si

Tabla 48: Filtros para los modelos de Crédito Privado en Moneda Nacional en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
media	0.48	0.66	0.21	0.38	0.22	0.66
sd	1.29	1.34	1.32	1.34	1.45	1.33
percentil 0 %	-3.99	-3.57	-4.53	-4.75	-3.73	-3.52
25 %	-0.33	-0.14	-0.56	-0.38	-0.67	-0.15
50 %	0.40	0.61	0.09	0.28	0.18	0.64
75 %	1.24	1.50	0.90	1.13	1.25	1.48
100 %	4.48	4.51	4.16	4.89	3.83	4.43

Tabla 49: Parámetros de la distribución de los errores en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	71.67	68.33	71.67	70	66.67	71.67
step 2	70	66.67	73.33	73.33	76.67	68.33
step 3	65	58.33	70	71.67	63.33	56.67
step 4	63.33	53.33	70	70	60	53.33
step 5	66.67	61.67	66.67	68.33	63.33	61.67
step 6	68.33	56.67	68.33	71.67	60	58.33

Tabla 50: Hit de las observaciones en las bandas de una desviación estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	96.67	95	96.67	93.33	96.67	95
step 2	96.67	96.67	95	93.33	93.33	96.67
step 3	95	96.67	95	95	96.67	96.67
step 4	93.33	95	95	93.33	96.67	95
step 5	90	88.33	93.33	90	93.33	90
step 6	88.33	90	93.33	91.67	100	88.33

Tabla 51: Hit de las observaciones en las bandas de dos desviaciones estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	98.33	98.33	98.33	98.33	100	98.33
step 2	98.33	98.33	98.33	98.33	100	98.33
step 3	100	100	100	100	100	100
step 4	100	100	100	100	100	100
step 5	100	100	100	100	100	100
step 6	100	100	100	100	100	100

Tabla 52: Hit de las observaciones en las bandas de tres desviaciones estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
media	4,802,963,509	6,544,584,473	2,215,448,287	3,927,974,571	2,201,686,867	6,523,846,704
sd	12,952,602,222	13,159,277,695	13,522,179,091	13,726,669,581	15,449,264,885	13,093,672,109
percentil 0 %	-39,772,443,000	-35,168,906,132	-45,246,298,246	-47,894,341,922	-37,061,553,702	-34,686,466,547
25 %	-3,097,724,877	-1,434,578,646	-5,381,905,103	-3,653,908,594	-7,502,556,649	-1,228,627,696
50 %	3,720,487,961	5,865,930,723	913,131,487	2,393,666,451	2,016,243,163	5,850,485,901
75 %	11,956,179,085	14,297,187,630	8,184,231,428	10,992,718,071	12,991,161,552	14,100,603,570
100 %	51,841,208,782	51,287,873,159	48,241,123,270	56,558,432,451	39,406,916,758	51,277,406,249

Tabla 53: Parámetros de la distribución de los errores de predicción en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	71.67	73.33	73.33	70	66.67	73.33
step 2	73.33	70	73.33	73.33	80	71.67
step 3	65	58.33	70	73.33	66.67	60
step 4	71.67	56.67	66.67	73.33	53.33	56.67
step 5	70	61.67	66.67	73.33	63.33	61.67
step 6	71.67	58.33	71.67	71.67	56.67	56.67

Tabla 54: Hit de las observaciones en las bandas de una desviación estándar en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	95	95	93.33	93.33	96.67	95
step 2	91.67	95	95	93.33	93.33	95
step 3	95	95	95	95	93.33	95
step 4	91.67	91.67	95	95	96.67	91.67
step 5	90	88.33	91.67	90	100	91.67
step 6	88.33	85	91.67	90	100	85

Tabla 55: Hit de las observaciones en las bandas de dos desviaciones estándar en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
step 1	98.33	98.33	98.33	98.33	100	98.33
step 2	98.33	98.33	98.33	98.33	100	98.33
step 3	100	100	100	98.33	100	100
step 4	100	100	100	100	100	100
step 5	100	100	100	100	100	100
step 6	98.33	98.33	100	98.33	100	98.33

Tabla 56: Hit de las observaciones en las bandas de tres desviaciones estándar en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
media	-0.02	-0.01	0.003	0.06	0.05	-0.008
sd	1.28	1.41	1.51	1.50	1.30	1.41
percentil 0 %	-9.39	-14.31	-6.53	-21.34	-6.70	-9.55
25 %	-0.74	-0.79	-0.83	-0.76	-0.69	-0.79
50 %	-0.08	-0.07	-0.04	-0.02	-0.002	-0.07
75 %	0.59	0.65	0.73	0.75	0.68	0.65
100 %	8.37	10.23	10.53	10.60	9.32	10.05

Tabla 57: Parámetros de la distribución de los errores de predicción en variación interanual con la data sintética, modelando en nivel

	Average	Best ARIMA	Best ETS	Minimum AIC ETS	Regression Forecast Combination	SARIMA
media	-0.03	0.01	-0.01	-0.07	-1.20	-0.05
sd	1.55	1.50	1.74	1.61	21.07	1.58
percentil 0 %	-6.04	-5.36	-5.82	-7.003	-65.67	-6.64
25 %	-0.90	-0.82	-1.10	-0.99	-8.33	-0.94
50 %	0.15	0.04	0.38	0.01	1.03	0.02
75 %	1.03	1.04	1.25	1.01	10.47	1.05
100 %	2.94	3.07	3.09	3.34	60.14	3.26

Tabla 58: Parámetros de la distribución de los errores de predicción modelando directamente la variación interanual

.0.5 IPC

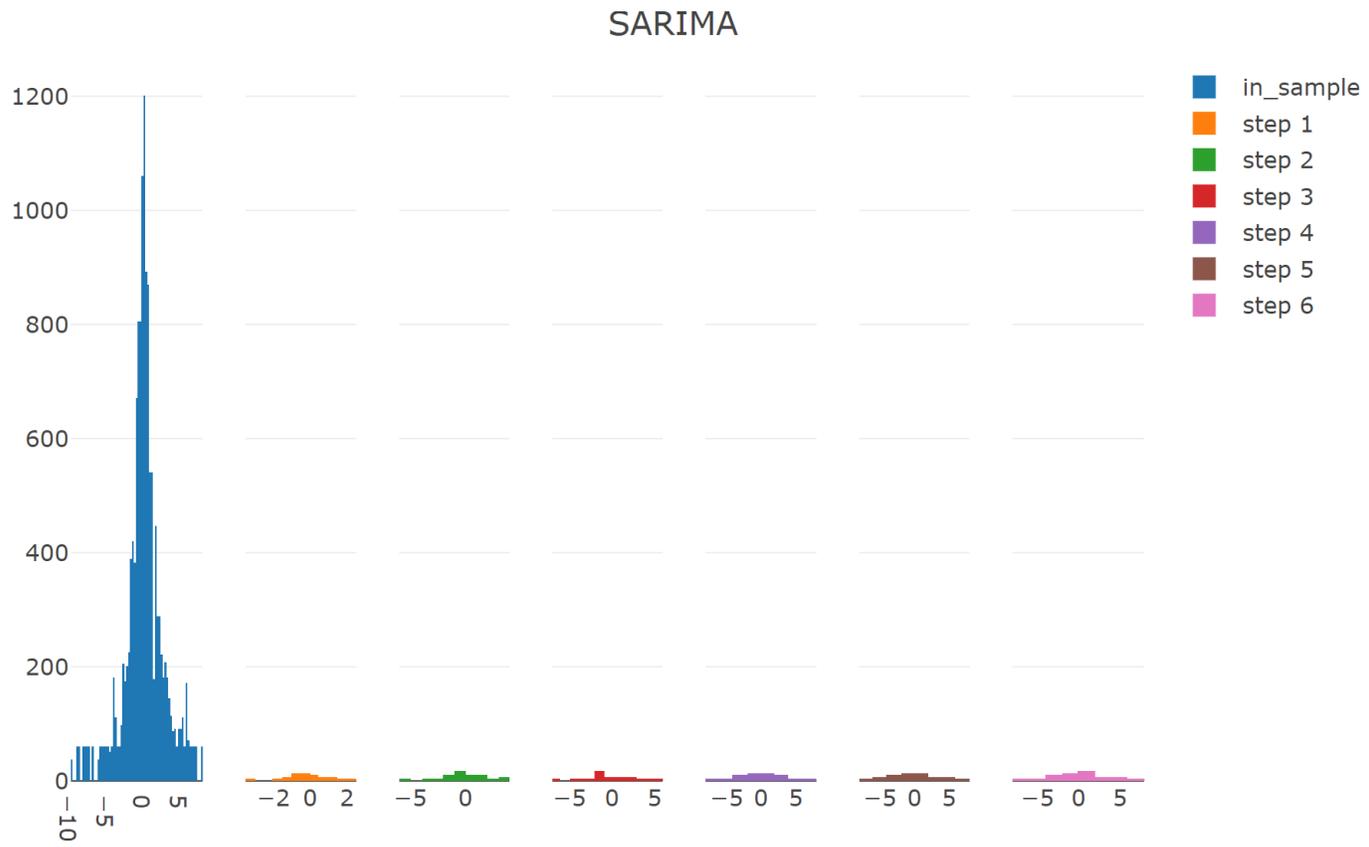


Figura 48. IPC: errores SARIMA

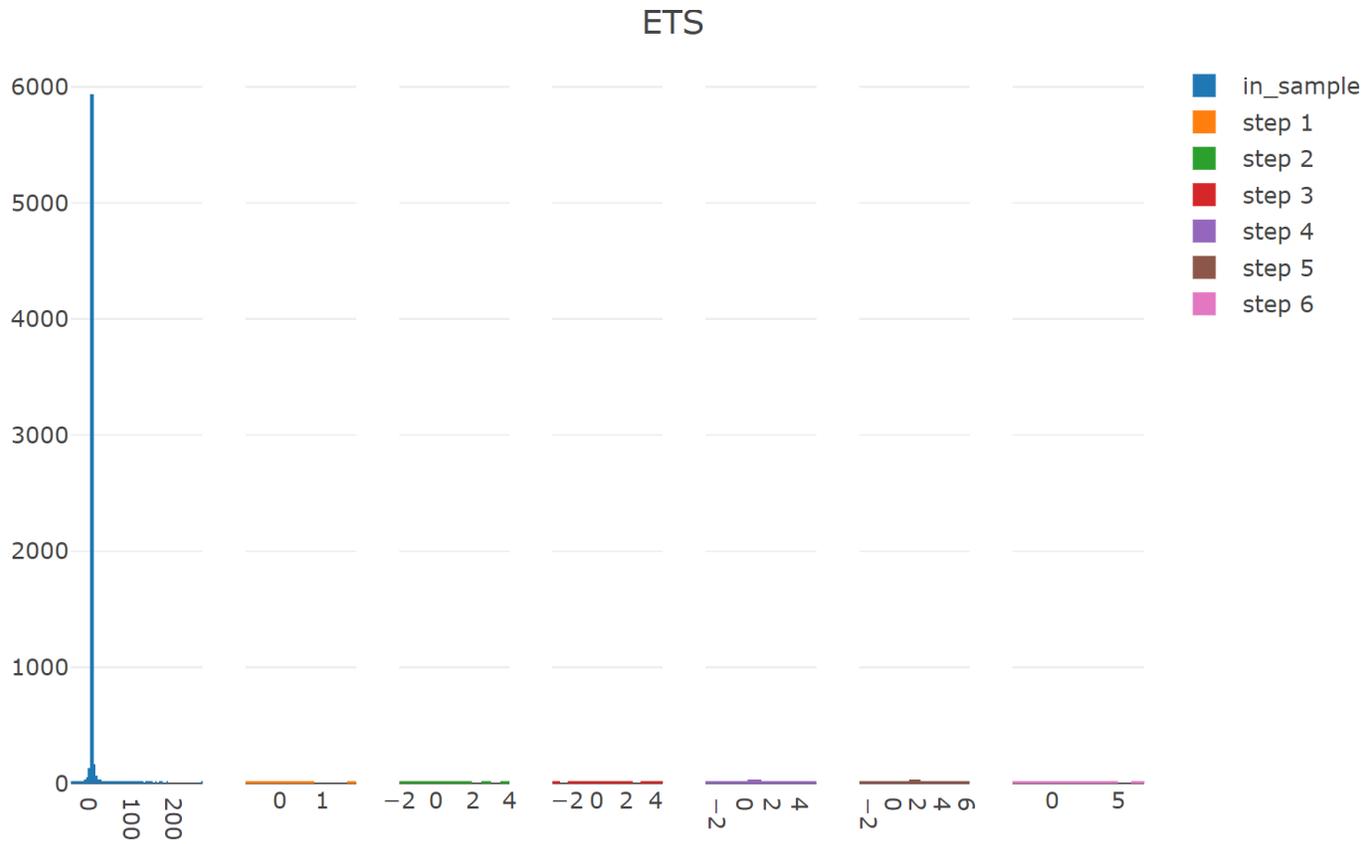


Figura 49. IPC: errores Minimum AIC ETS

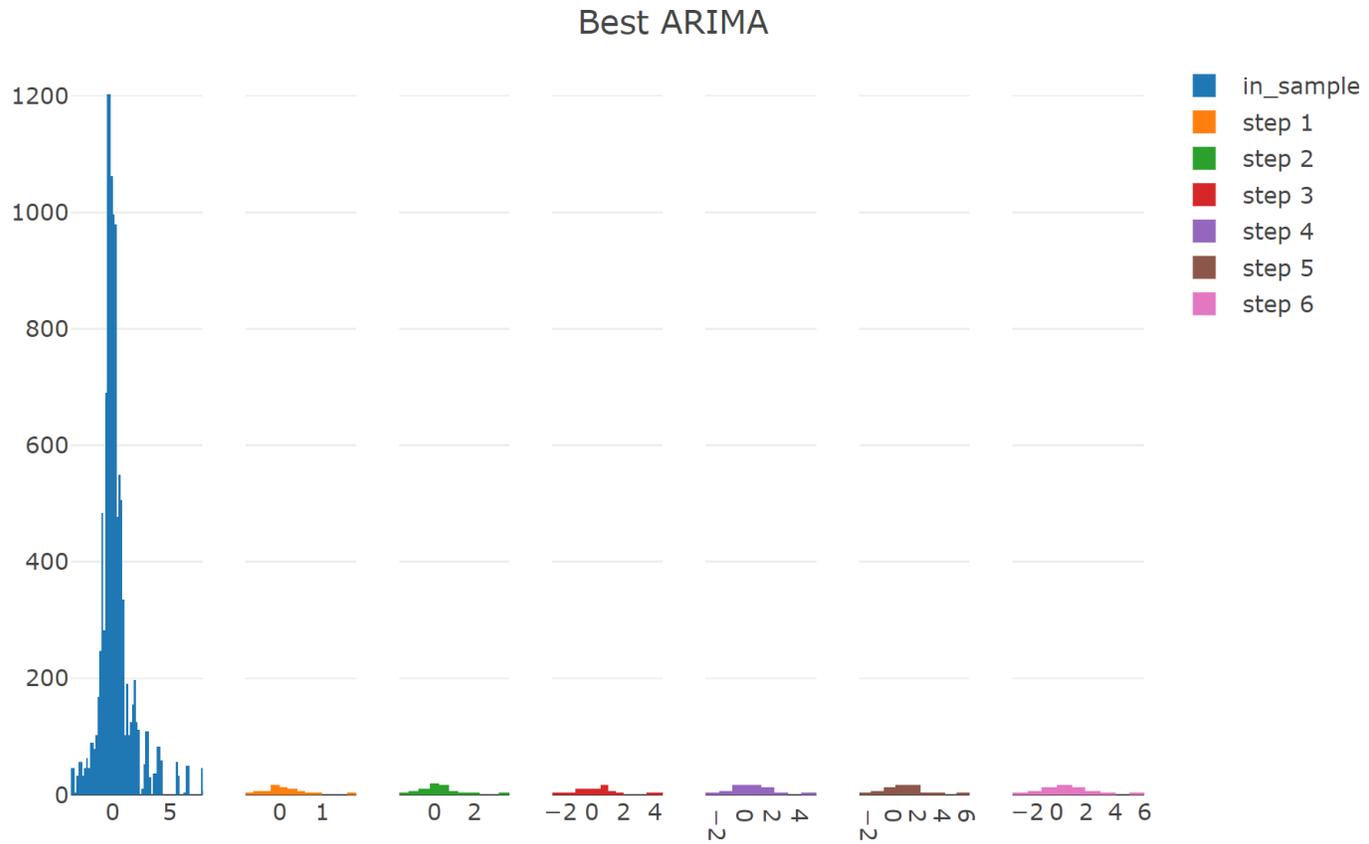


Figura 50. IPC: errores Grid/Best ARIMA

Best ETS

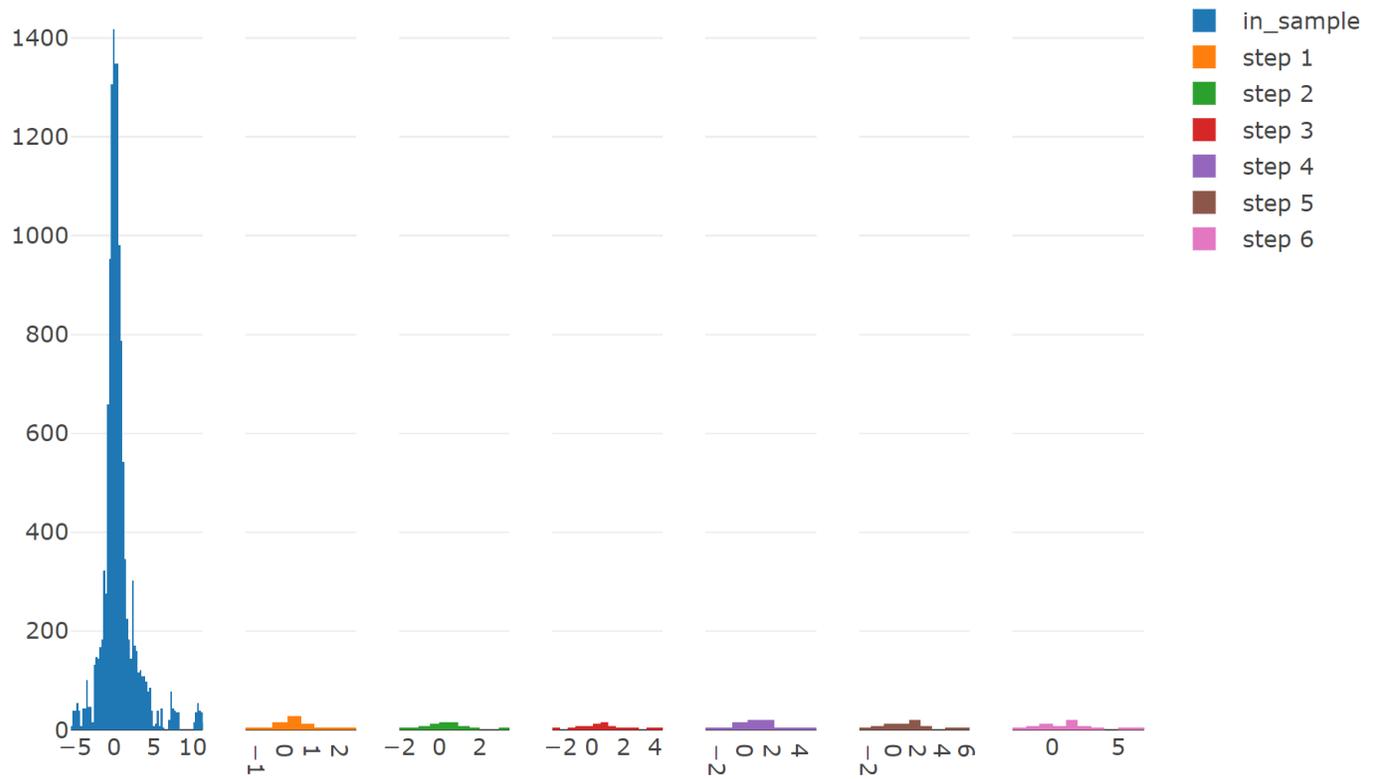


Figura 51. IPC: errores Grid/Best ETS

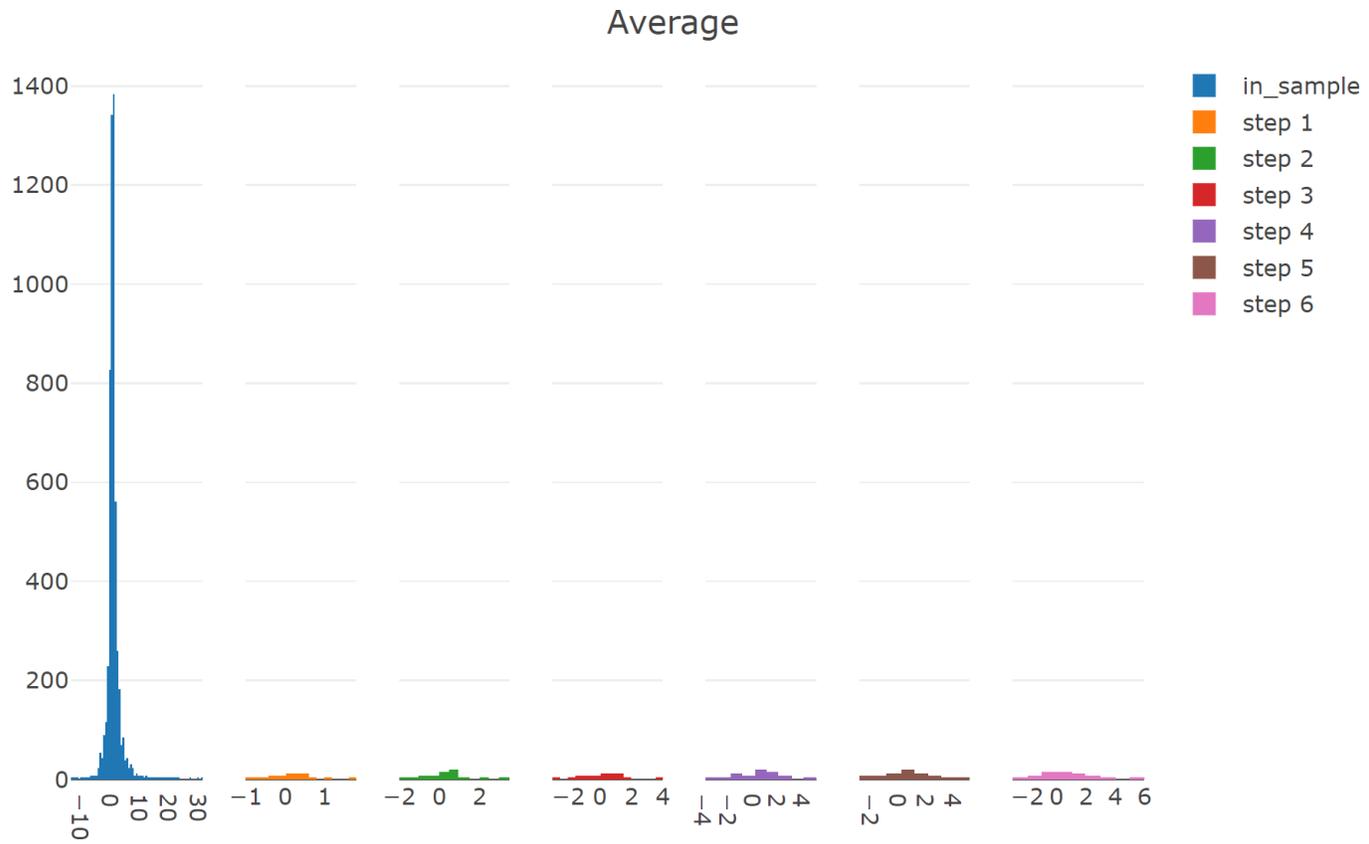


Figura 52. IPC: errores Grid/Best Average Forecast Combination

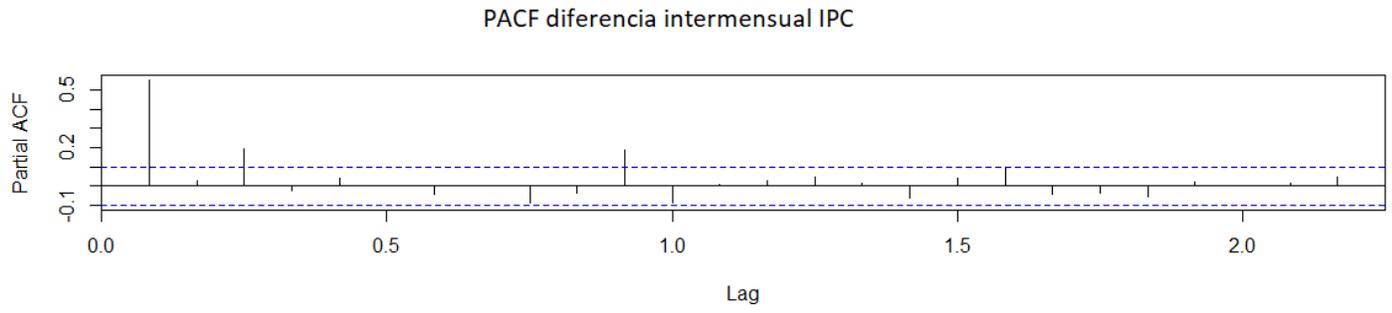


Figura 55. IPC: PACF de la diferencia intermensual

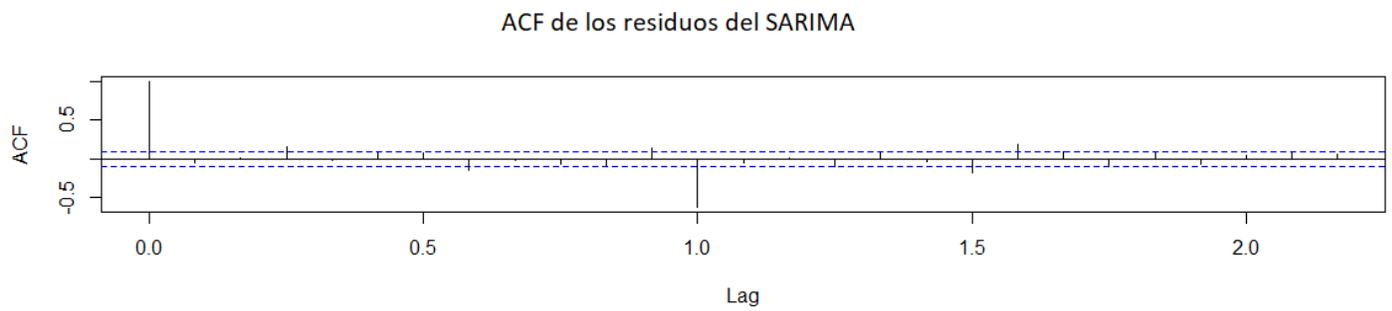


Figura 56. IPC: ACF de los residuos del SARIMA. P-value del Box-Pierce test = 0.27

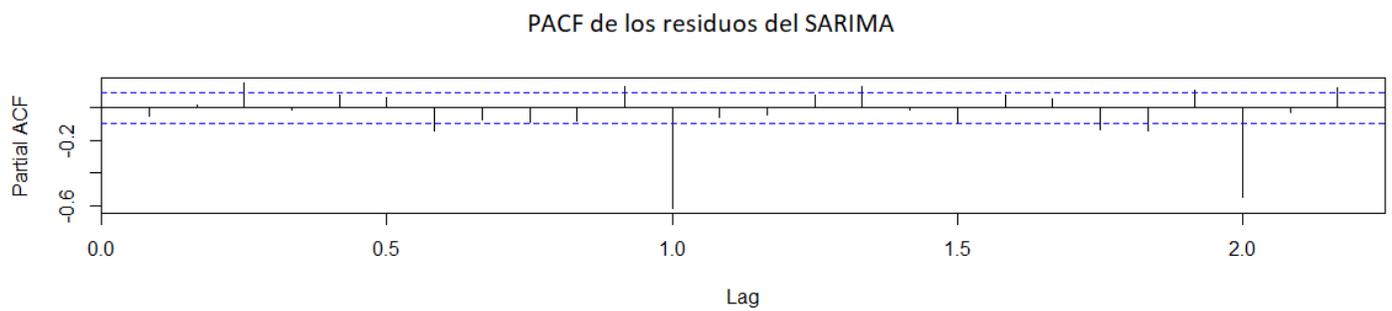


Figura 57. IPC: PACF de los residuos del SARIMA

	Average Combination	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.41	0.41	0.59	0.72	0.73	-0.07
sd	1.27	1.21	1.27	1.33	1.34	2.49
percentil 0 %	-3.00	-2.64	-2.44	-2.34	-1.29	-7.25
25 %	-0.30	-0.28	-0.22	-0.08	-0.18	-1.49
50 %	0.25	0.31	0.48	0.43	0.51	-0.21
75 %	1.01	0.91	1.19	1.31	1.48	1.30
100 %	5.62	5.55	6.33	7.25	5.37	7.41

Tabla 59: Parámetros de la distribución de los errores de predicción en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	70	75	75	73.33	76.66666667	65
step 2	70	76.67	75	76.67	83.33	70
step 3	71.67	80	75	76.67	80	73.33
step 4	73.33	73.33	75	71.67	73.33	66.67
step 5	71.67	71.67	73.33	65	73.33	70
step 6	68.33	63.33	65	66.67	66.67	68.33

Tabla 60: Hit de las observaciones en las bandas de una desviación estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	96.67	96.67	93.33	96.67	96.67	95
step 2	96.67	96.67	95	96.67	93.33	95
step 3	95	95	95	93.33	93.33	95
step 4	95	95	95	95	93.33	93.33
step 5	95	95	95	93.33	93.33	93.33
step 6	93.33	95	93.33	93.33	93.33	95

Tabla 61: Hit de las observaciones en las bandas de dos desviaciones estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	98.33	98.33	98.33	96.67	96.67	98.33
step 2	98.33	98.33	96.67	98.33	96.67	98.33
step 3	96.67	96.67	96.67	96.67	93.33	100
step 4	96.67	96.67	96.67	96.67	93.33	100
step 5	98.33	96.67	96.67	96.67	93.33	100
step 6	98.33	96.67	95	96.67	93.33	100

Tabla 62: Hit de las observaciones en las bandas de tres desviaciones estándar en variación interanual, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.15	-0.01	0.29	0.35	0.01	0.01
sd	1.23	1.08	1.20	1.13	1.16	2.49
percentil 0 %	-7.98	-11.27	-7.12	-9.87	-9.04	-16.07
25 %	-0.39	-0.52	-0.23	-0.11	-0.49	-0.96
50 %	0.04	-0.15	0.10	0.14	-0.06	0.10
75 %	0.58	0.28	0.66	0.66	0.35	1.13
100 %	8.60	7.90	9.23	9.51	9.04	18.93

Tabla 63: Parámetros de la distribución de los errores de predicción en variación interanual con la data sintética, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	-0.03	-0.13	0.11	0.06	0.71	-0.15
sd	1.44	1.50	1.65	1.98	2.16	1.35
percentil 0 %	-3.69	-4.23	-3.93	-5.42	-4.66	-4.18
25 %	-0.88	-1.09	-1.03	-0.94	-0.53	-0.85
50 %	0.07	0.002	0.26	0.001	0.52	-0.10
75 %	0.76	0.60	1.08	1.03	1.62	0.49
100 %	4.73	4.30	4.37	7.87	7.36	4.79

Tabla 64: Parámetros de la distribución de los errores en variación interanual modelando directamente la variación interanual

	Average Combination	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
media	0.43	0.45	0.63	0.77	0.75	-0.12
sd	1.29	1.25	1.30	1.37	1.42	2.61
percentil 0 %	-2.97	-2.61	-2.42	-2.31	-1.57	-8.37
25 %	-0.30	-0.29	-0.23	-0.09	-0.20	-1.64
50 %	0.26	0.31	0.51	0.47	0.55	-0.21
75 %	1.03	0.96	1.22	1.38	1.59	1.35
100 %	5.65	5.57	6.37	7.22	5.43	7.71

Tabla 65: Parámetros de la distribución de los errores en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	73.33	75	76.67	71.67	73.33	71.67
step 2	71.67	76.67	73.33	70	83.33	76.67
step 3	66.67	78.33	75	70	76.67	73.33
step 4	68.33	73.33	73.33	65	70	70
step 5	70	68.33	70	66.67	70	66.67
step 6	66.67	65	71.67	66.67	63.33	70

Tabla 66: Hit de las observaciones en las bandas de una desviación estándar en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	96.67	96.67	93.33	96.67	96.67	96.67
step 2	96.67	96.67	95	96.67	93.33	95
step 3	95	95	95	93.33	93.33	95
step 4	95	96.67	95	95	93.33	93.33
step 5	95	93.33	95	93.33	93.33	93.33
step 6	93.33	91.67	91.67	93.33	93.33	95

Tabla 67: Hit de las observaciones en las bandas de dos desviaciones estándar en nivel, modelando en nivel

	Average	Best ARIMA	Best ETS	ETS	Regression Forecast Combination	SARIMA
step 1	98.33	98.33	98.33	96.67	96.67	98.33
step 2	98.33	98.33	96.67	98.33	96.67	98.33
step 3	96.67	96.67	96.67	96.67	93.33	100
step 4	96.67	96.67	96.67	96.67	93.33	100
step 5	98.33	96.67	96.67	96.67	93.33	100
step 6	98.33	96.67	95	96.67	93.33	100

Tabla 68: Hit de las observaciones en las bandas de tres desviaciones estándar en nivel, modelando en nivel

.0.6 Llegada de Turistas

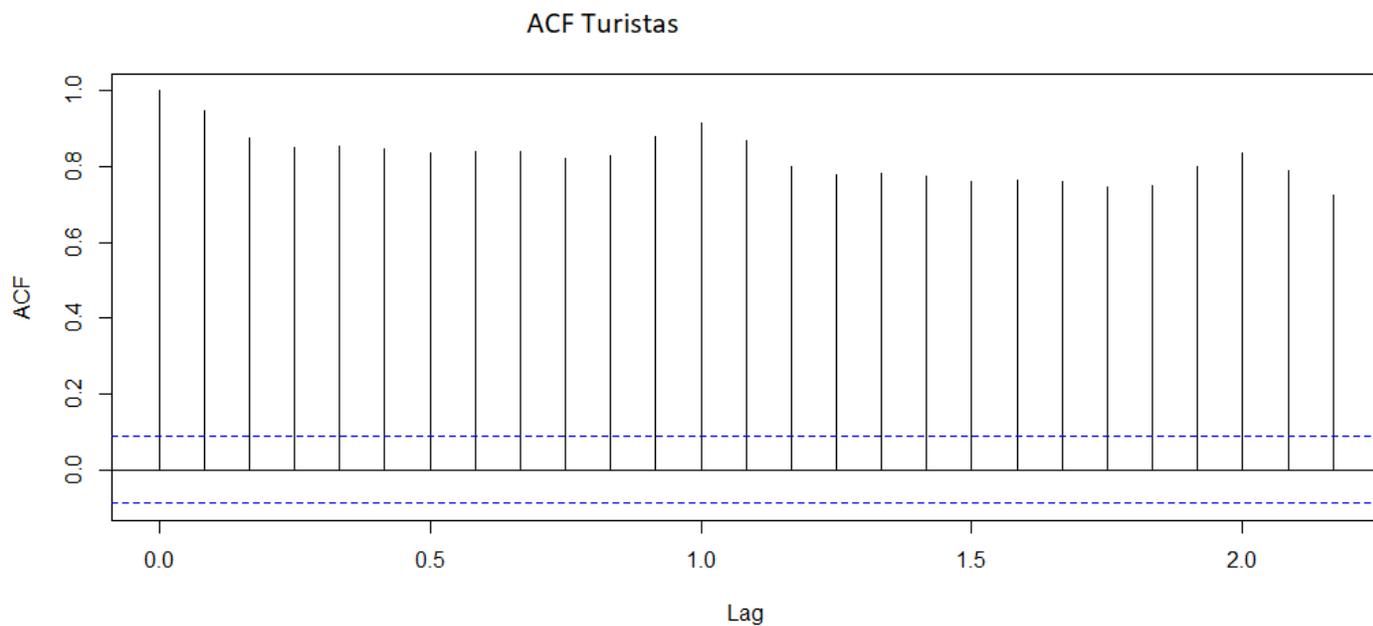


Figura 58. Llegada de Turistas: ACF en niveles. P-value del KPSS test mayor que 0.1

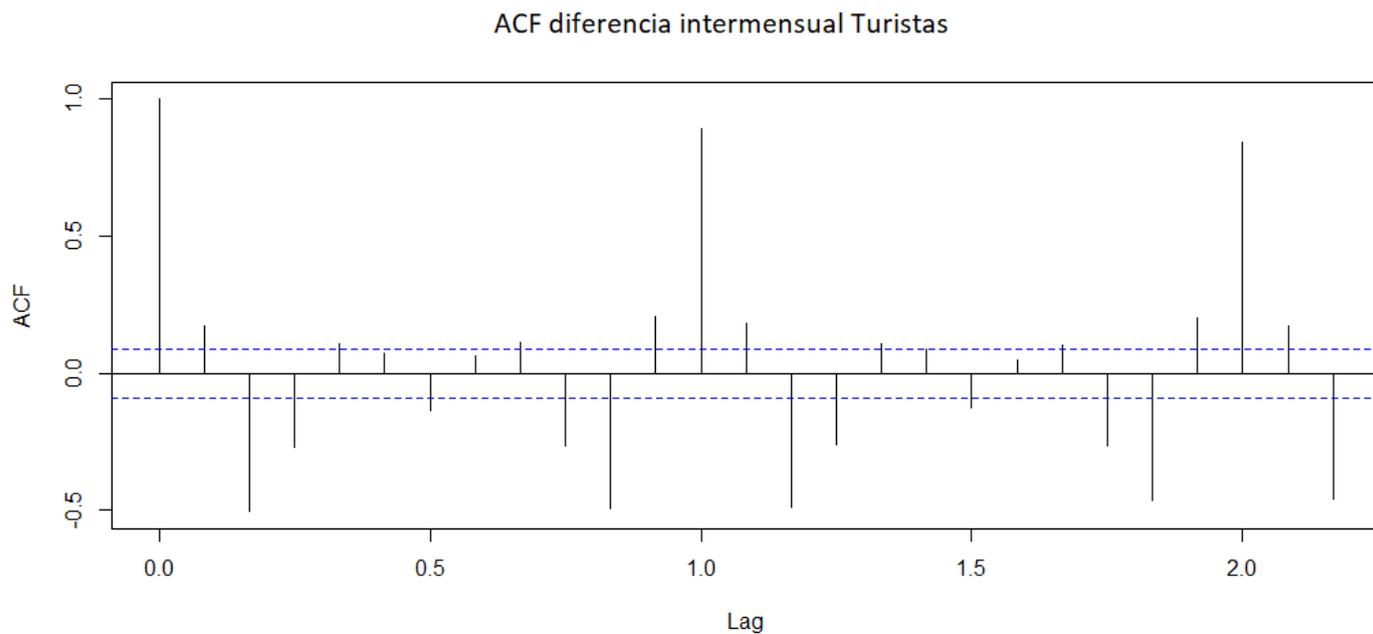


Figura 59. Llegada de Turistas: ACF de la variable en diferencias. La variable en diferencia intermensual pasó los tests de estacionariedad a niveles de significancia convencionales

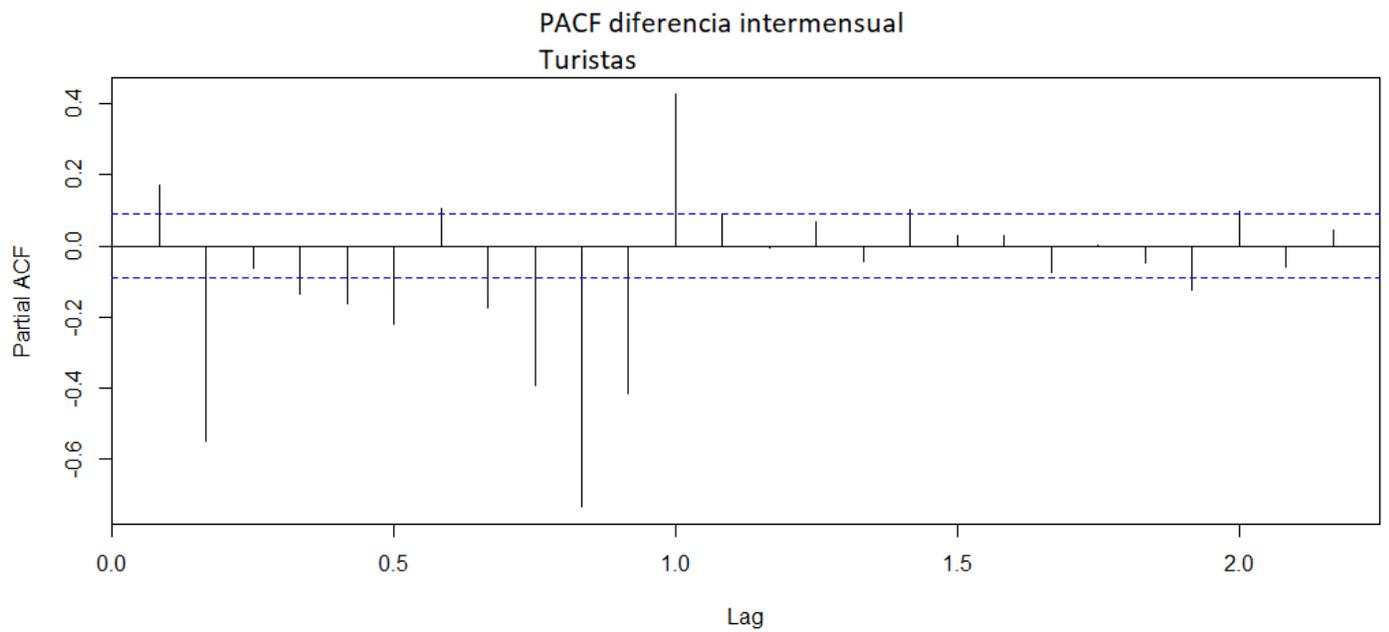


Figura 60. Llegada de Turistas: ACF de la variable en diferencias.

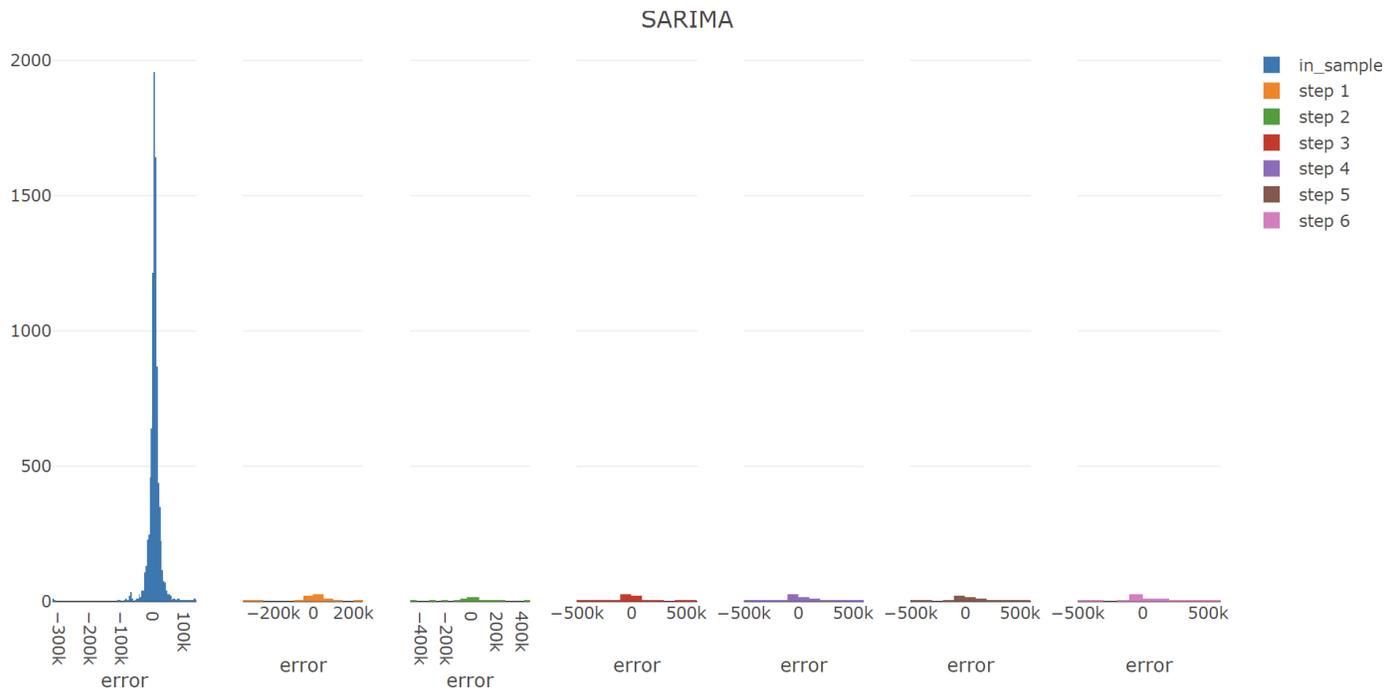


Figura 61. Llegada de Turistas: Errores Box-Jenkins SARIMA.

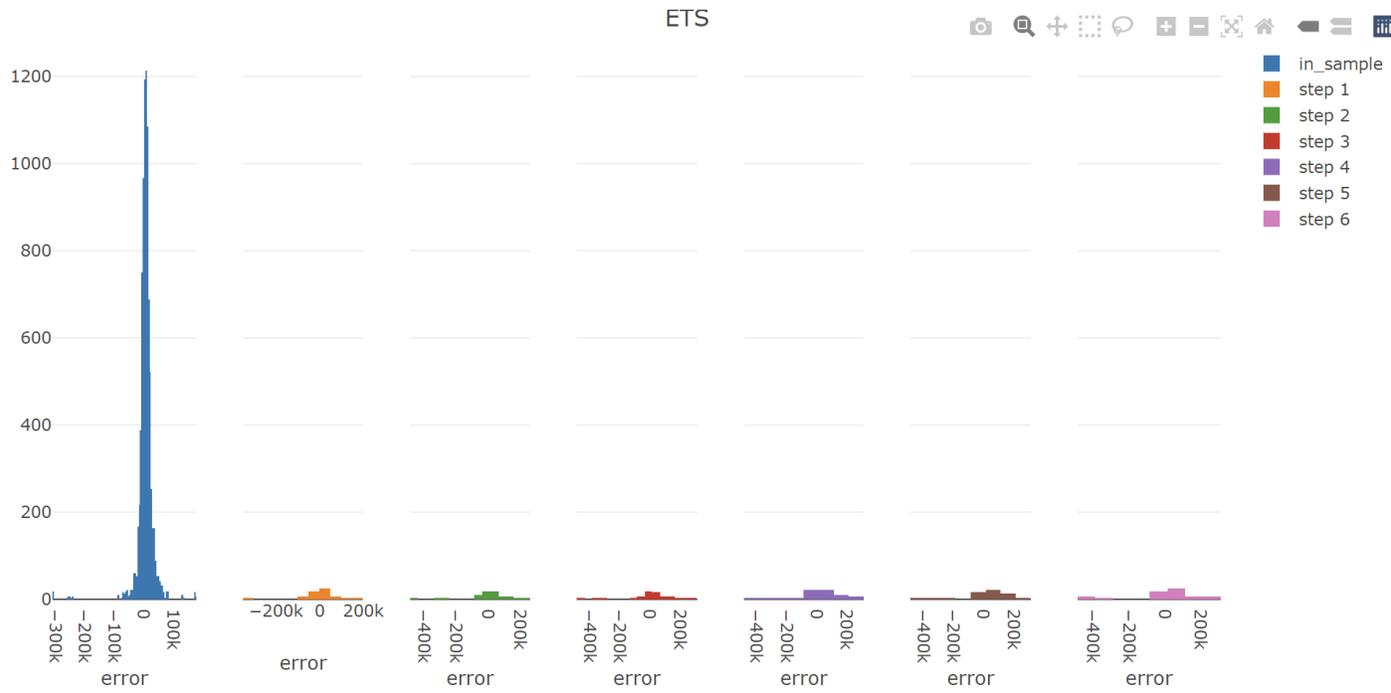


Figura 62. Llegada de Turistas: Errores Minimum AIC ETS.

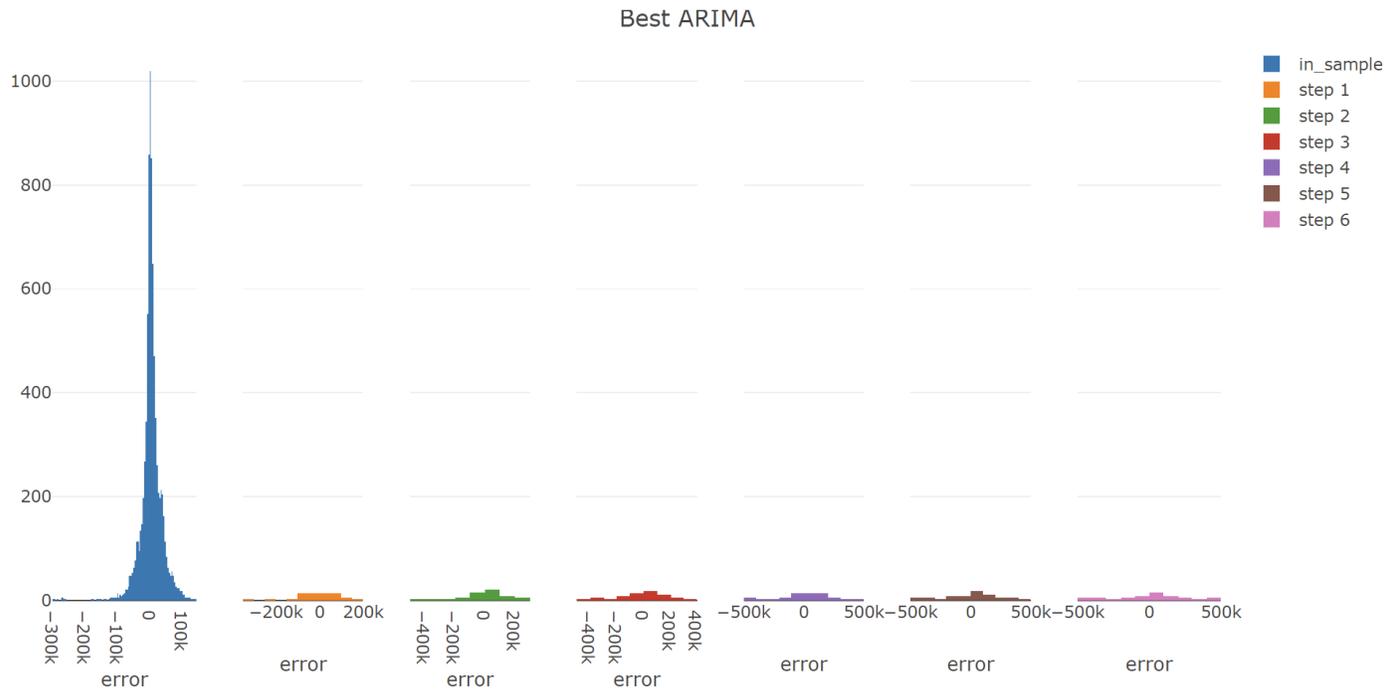


Figura 63. Llegada de Turistas: Errores Grid/Best ARIMA.

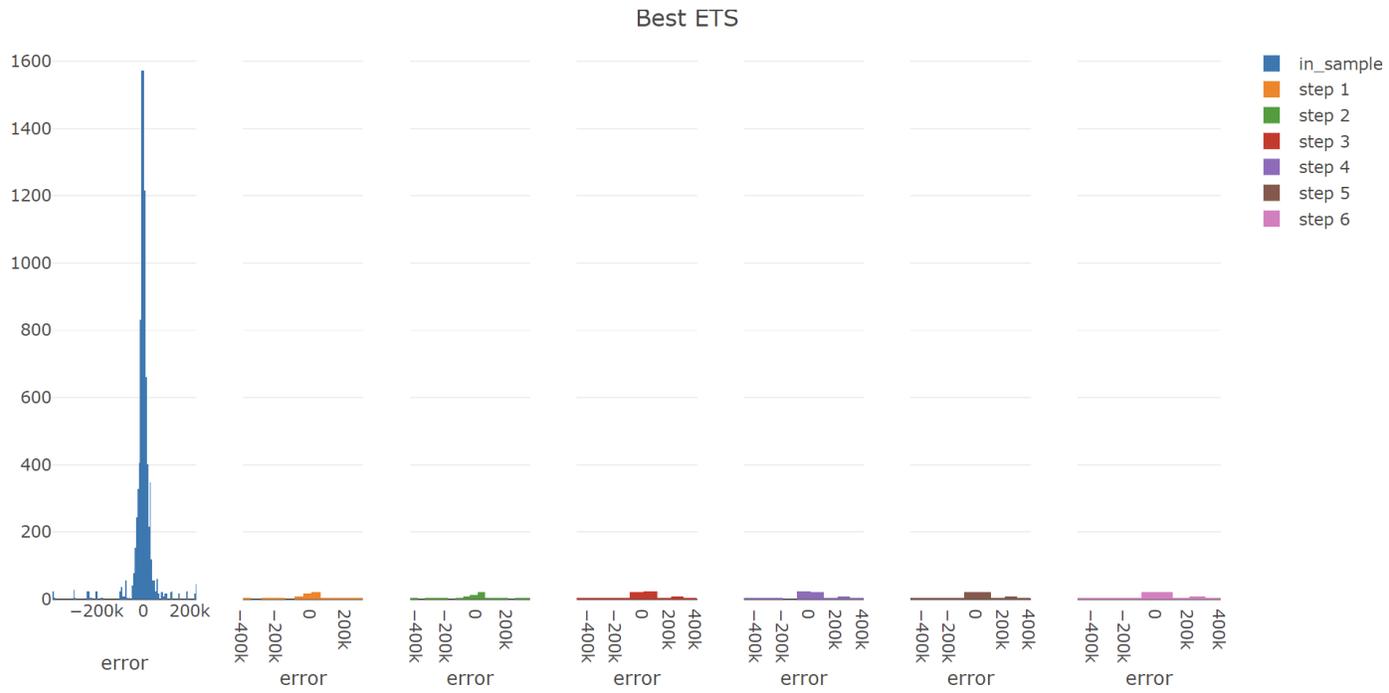


Figura 64. Llegada de Turistas: Errores Grid/Best ETS.

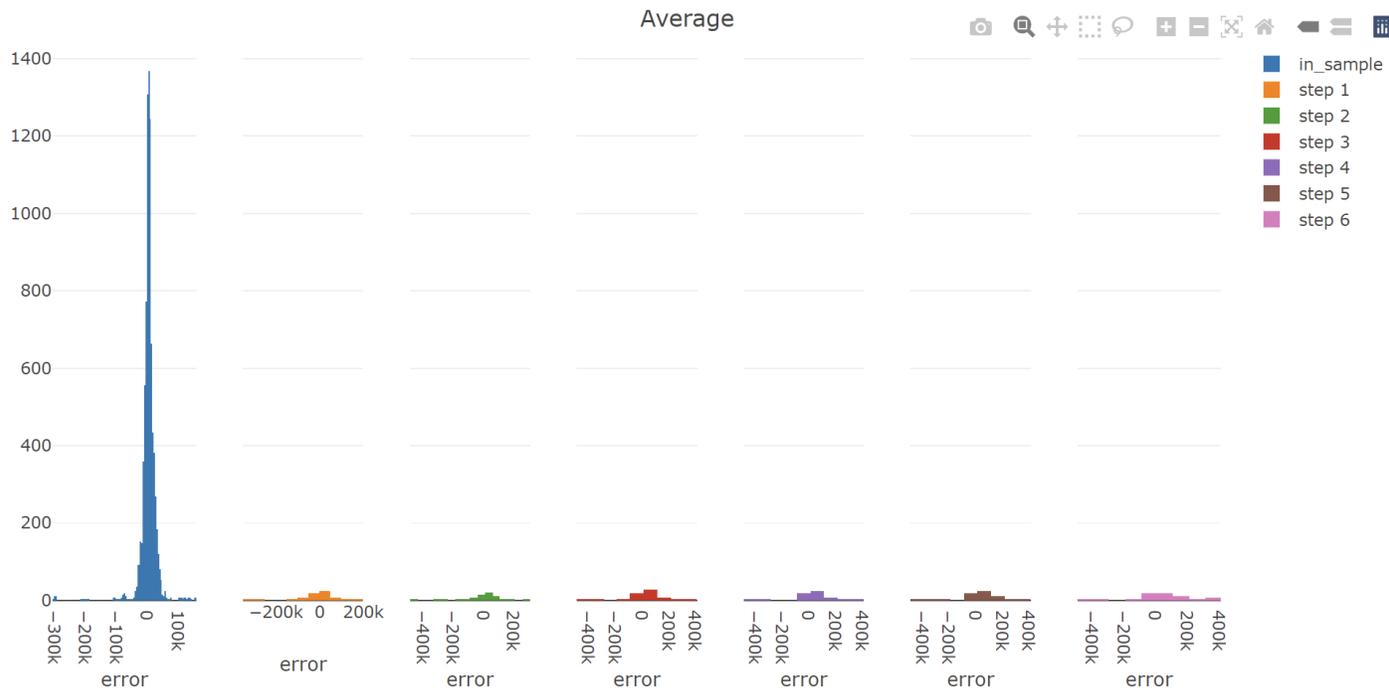


Figura 65. Llegada de Turistas: Errores Average Forecast Combination.

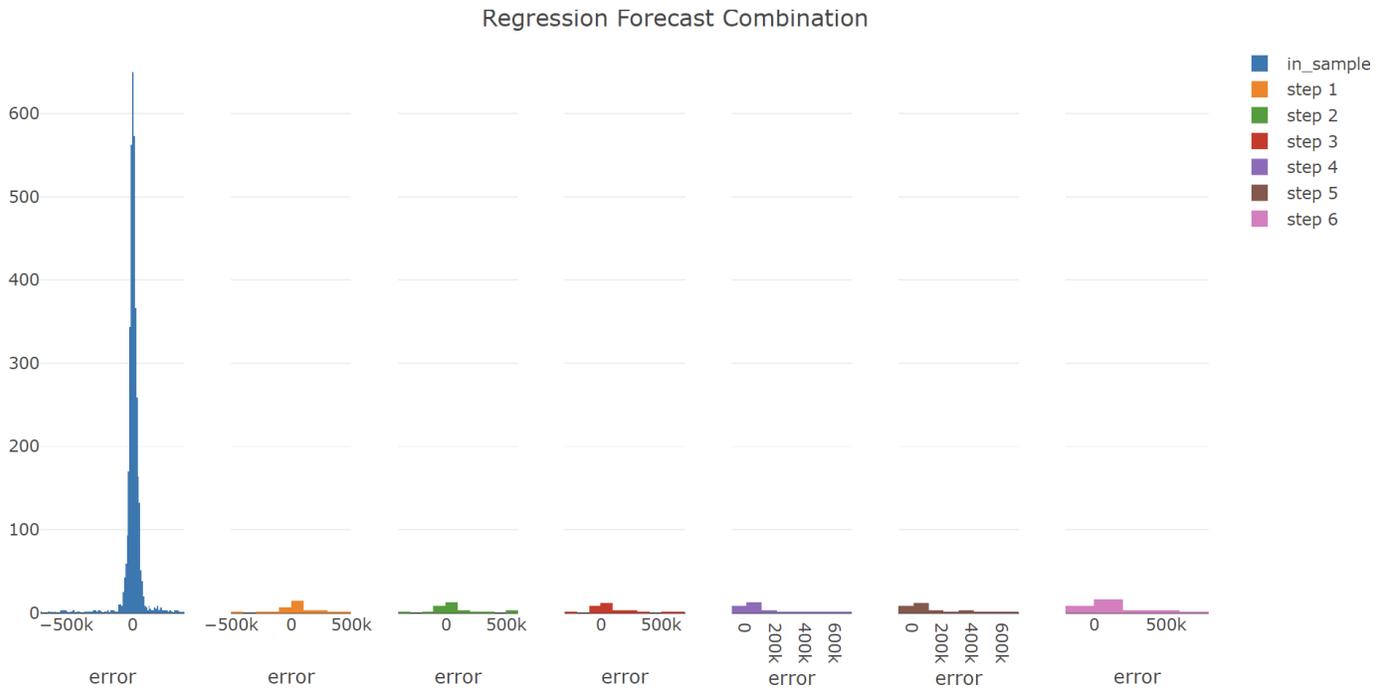


Figura 66. Llegada de Turistas: Errores Regression Forecast Combination.

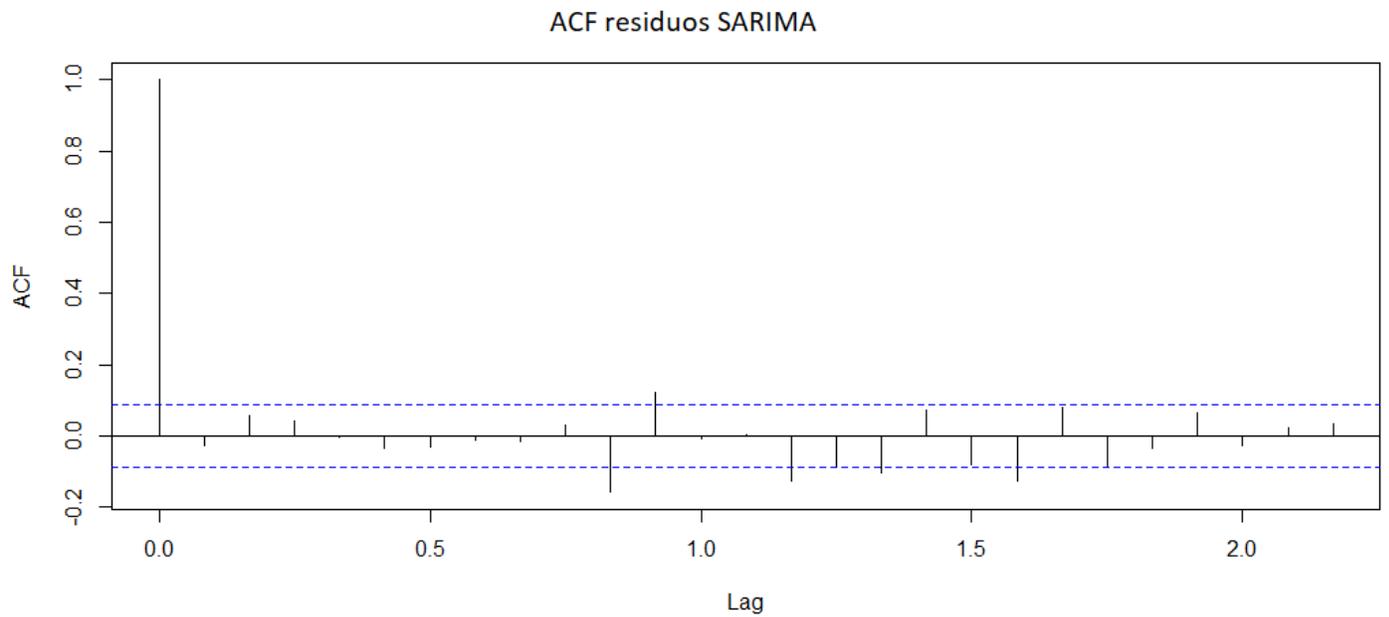


Figura 67. Llegada de Turistas: ACF de los residuos del Box-Jenkins SARIMA.

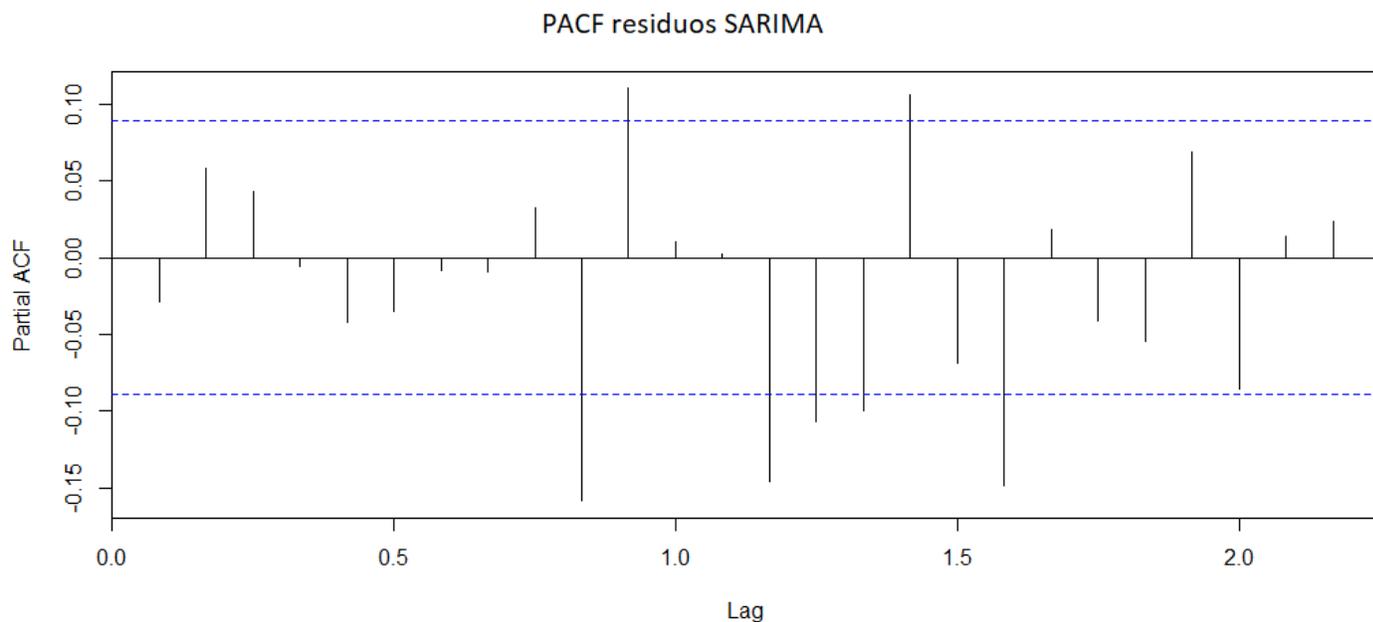


Figura 68. Llegada de Turistas: PACF de los residuos del Box-Jenkins SARIMA.

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
media	13,588	1,247	13,016	7,874	8,931	1,560
sd	162,136	131,586	175,599	145,676	141,378	145,152
percentil 0 %	-468,914	-461,065	-488,746	-440,271	-461,922	-420,339
25 %	-29,711	-23,179	-72,578	-31,502	-28,928	-64,736
50 %	1,066	5,219	20,709	5,533	14,489	-1,958
75 %	60,588	57,374	104,784	52,744	64,402	75,079
100 %	580,395	296,827	464,619	366,564	387,206	422,118

Tabla 69: Parámetros de la distribución de los errores de predicción para Turistas

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	83.33	90	73.33	81.67	85	80
step 2	86.67	85	73.33	81.67	83.33	80
step 3	81.67	85	70	78.33	80	80
step 4	81.67	81.67	75	78.33	81.67	83.33
step 5	80	78.33	75	73.33	78.33	80
step 6	76.67	75	70	71.67	76.67	76.67

Tabla 70: Hit de las observaciones en las bandas de una desviación estándar para Turistas

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	95	95	95	90	95	90
step 2	95	91.67	95	90	93.33	90
step 3	91.67	91.67	93.33	90	90	90
step 4	90	91.67	88.33	93.33	88.33	90
step 5	88.33	91.67	96.67	91.67	90	86.67
step 6	90	90	93.33	93.33	91.67	86.67

Tabla 71: Hit de las observaciones en las bandas de dos desviaciones estándar para Turistas

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	95	96.67	98.33	98.33	96.67	100
step 2	96.67	98.33	98.33	98.33	98.33	96.67
step 3	96.67	96.67	100	98.33	98.33	93.33
step 4	98.33	96.67	100	100	100	96.67
step 5	100	100	100	100	100	96.67
step 6	100	100	100	100	100	93.33

Tabla 72: Hit de las observaciones en las bandas de tres desviaciones estándar para Turistas

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
media	-162	3,968	5,475	5,284	2,221	10,060
sd	66,310	79,028	68,301	78,327	33,827	51,199
percentil 0%	-625,997	-488,172	-487,097	-440,784	-247,877	209,176
25%	-18,713	-21,377	-13,959	-15,451	-9,509	-8,031
50%	148	1,526	3,335	3,428	2,194	3,661
75%	17,690	32,113	28,062	35,382	15,636	18,654
100%	678,743	330,715	407,459	394,072	205,994	491,302

Tabla 73: Parámetros de la distribución de los errores de predicción para Turistas con data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	73.24	70.80	71.28	69.87	88.65	75.7
step 2	74.72	71.29	71.07	69.5	80.17	69.1
step 3	73.79	71.08	68.53	68.45	75.35	67.6
step 4	72.54	71.52	68.52	68.87	74.19	65.47
step 5	73.31	74.75	68.67	70.12	72.59	64.73
step 6	74.20	74.67	70.07	69.32	68.15	66.37

Tabla 74: Hit de las observaciones en las bandas de una desviación estándar para Turistas con data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	94.54	95.45	94.68	94.8	98.52	82.5666667
step 2	94.25	95.65	94.85	94.73	94.56	80.03
step 3	93.82	96.28	94.93	94.25	93.28	78.63
step 4	93.89	95.52	94.53	94.08	91.77	77.7
step 5	93.01	94.08	93.93	93.72	90.72	76.5
step 6	93.16	93.46	93.62	93.78	88.05	75.17

Tabla 75: Hit de las observaciones en las bandas de dos desviaciones estándar para Turistas con data sintética

	SARIMA	ETS	Best ARIMA	Best ETS	Average	Regression Combination
step 1	99.12	99.13	99.23	99.32	99.58	83.5
step 2	98.71	99.06	99.45	99.45	98.65	82.47
step 3	99.01	98.68	99.52	99.5	97.61	82.1
step 4	99.45	98.81	99.3	99.43	97.12	81.43
step 5	99.35	98.85	99.08	99.27	96.03	80.97
step 6	98.83	98.90	98.77	99.12	94.01	79.6

Tabla 76: Hit de las observaciones en las bandas de tres desviaciones estándar para Turistas con data sintética